


**Științele
educației**

Adrian Vicențiu Labăr

SPSS PENTRU ȘTIINȚELE EDUCAȚIEI



III 236 239

Collegium

POLIROM

BIBL. CENTR. UNIV.
„M. EMINESCU” IAȘI

III 296.239

COLLEGIUM
Științele educației

Seria *Collegium. Științele educației* este coordonată de Constantin Cucoș.

Adrian Vicențiu Labăr este doctorand al Facultății de Psihologie și Științele Educației, Universitatea „Al.I. Cuza”, Iași, asistent asociat în cadrul aceleiași facultăți. Domeniile sale de competență sunt analiza statistică a datelor în SPSS, metodologia cercetării în științele educației și psihodiagnoza indivizilor înalt abilitați. A publicat „Radiografii asupra spațiului românesc. Linii de mentalitate”, în *Analele Științifice ale Universității „Al.I. Cuza” din Iași*, Seria Pedagogie (2003), „Consecințe ale educației religioase asupra formării conduitelor tinerilor. Perspectiva beneficiarilor”, în *Revista de psihologie și științele educației* (coautor, 2007).

© 2008 by Editura POLIROM

www.polirom.ro

Editura POLIROM

Iași, B-dul Carol I nr. 4; P.O. Box 266, 700506

București, B-dul I.C. Brătianu nr. 6, et. 7, ap. 33, O.P. 37;

P.O. Box 1-728, 030174

Descrierea CIP a Bibliotecii Naționale a României:

LABĂR, ADRIAN VICENȚIU

SPSS pentru științele educației: metodologia analizei datelor în cercetarea pedagogică /
Adrian Vicențiu Labăr ; pref. de Constantin Cucoș. — Iași : Polirom, 2008

Bibliogr.

Index

ISBN 978-973-46-1148-5

I. Cucoș, Constantin (pref.)

004.42 SPSS:371

Printed in ROMANIA

Adrian Vicențiu Labăr

SPSS PENTRU ȘTIINȚELE EDUCAȚIEI

Metodologia analizei datelor
în cercetarea pedagogică

Cuvânt înainte de Constantin Cucos



434117

B.C.U. IASI

POLIROM
2008

BCUIASI/CENTRAL UNIVERSITY LIBRARY



21 OCT. 2008

Cuprins

<i>Cuvânt înainte</i> (Constantin Cucos)	11
Introducere	13
Capitolul 1. Introducere în SPSS	15
1.1. Realizarea unei baze de date	15
1.2. Operații statistice de bază. Tabele de frecvență	19
1.2.1. <i>Tabele de frecvență. Ilustrarea compoziției lotului de subiecți</i>	20
1.2.2. <i>Tabele de frecvență. Analiza răspunsurilor subiecților la un item</i>	24
1.2.3. <i>Tabele de frecvență. Verificarea bazei de date</i>	27
1.3. Operații statistice introductive. Calcularea indicatorilor statistici de bază pentru <u>variabile cantitative</u> : media, mediana etc.	29
1.4. Operații statistice introductive. Calcularea indicatorilor statistici de bază pentru variabile cantitative, în cazul unor distribuții bivariate	30
Capitolul 2. Reprezentarea grafică a variabilelor	33
2.1. Prezentarea grafică a distribuției de frecvențe pentru ilustrarea compoziției lotului de subiecți	33
2.1.1. <i>Ilustrarea întregului lot de subiecți în funcție de anumite variabile categoricale</i>	33
2.1.2. <i>Ilustrarea unei părți a lotului de subiecți în funcție de anumite variabile categoricale</i>	36
2.2. Prezentarea grafică a distribuției de frecvențe în general	39
2.2.1. <i>Grafice pentru distribuții de frecvențe în cazul unei singure variabile nominale sau ordinale</i>	39
2.2.2. <i>Grafice pentru distribuții de frecvențe în cazul încrucișării a două variabile nominale sau ordinale</i>	42
2.3. Prezentarea grafică a distribuției variabilelor cantitative	44
2.3.1. <i>Grafice pentru o singură variabilă cantitativă</i>	44
2.3.2. <i>Grafice pentru o variabilă cantitativă în funcție de nivelele altei/altor variabile calitative</i>	48
2.3.3. <i>Grafice pentru două variabile cantitative</i>	54
Capitolul 3. Analiza răspunsurilor multiple	61
3.1. Prezentare generală	61
3.2. Analiza răspunsurilor multiple dihotomice	61
3.2.1. <i>Aplicarea analizei răspunsurilor multiple dihotomice</i>	62
3.2.2. <i>Interpretarea outputului</i>	65
3.3. Analiza răspunsurilor multiple	66
3.3.1. <i>Aplicarea analizei răspunsurilor multiple</i>	67
3.3.2. <i>Interpretarea outputului</i>	69
3.4. Analiza răspunsurilor multiple în funcție de o variabilă nominală	70
3.4.1. <i>Analiza răspunsurilor diferențiat, după nivelele unei variabile nominale</i>	70
3.4.2. <i>Interpretarea outputului</i>	72
Capitolul 4. Noțiuni de bază privind testarea ipotezelor statistice	74
4.1. Ipoteze unidirecționale și ipoteze bidirecționale	74
4.2. Erorile de tipul I și cele de tipul II în testarea ipotezelor	74
4.3. Testarea normalității unei distribuții	75
4.3.1. <i>Demersul grafic</i>	76

4.3.2. Demersul statistic	77
4.4. Mărimea efectului	82
Capitolul 5. Analiza corelațională	84
5.1. Corelația Pearson și coeficientul de corelație r Pearson	84
5.1.1. Prezentare generală	84
5.1.2. Calcularea coeficientului de corelație r Pearson	85
5.1.3. Interpretarea outputului	86
5.1.4. Prezentarea rezultatelor	87
5.2. Corelația Spearman și coeficientul de corelație ρ Spearman	87
5.2.1. Prezentare generală	87
5.2.2. Calcularea coeficientului de corelație ρ Spearman	88
5.2.3. Interpretarea outputului	89
5.3. Corelația Kendall și coeficientul de corelație Kendall τ	90
5.3.1. Calcularea coeficientului de corelație Kendall τ	90
5.3.2. Interpretarea outputului	91
5.4. Corelația parțială	91
5.4.1. Prezentare generală	91
5.4.2. Calcularea coeficientului de corelație parțială	92
5.4.3. Interpretarea outputului	92
Capitolul 6. Teste t parametrice pentru comparare de medii	95
6.1. Testul t pentru un eșantion (One-Sample T Test)	95
6.1.1. Prezentare generală	95
6.1.2. Aplicarea testului t pentru un eșantion	95
6.1.3. Interpretarea outputului	96
6.2. Testul t pentru două eșantioane independente (Independent-Samples T Test)	97
6.2.1. Prezentare generală	97
6.2.2. Aplicarea testului t pentru eșantioane independente	98
6.2.3. Interpretarea outputului	99
6.2.4. Prezentarea rezultatelor	100
6.3. Testul t pentru două eșantioane perechi (Paired-Samples T Test)	100
6.3.1. Prezentare generală	100
6.3.2. Aplicarea testului t pentru eșantioane perechi	101
6.3.3. Interpretarea outputului	102
Capitolul 7. Teste neparametrice pentru un eșantion	104
7.1. Testul binomial de verificare a egalității unei proporții cu o valoare specificată	104
7.1.1. Aplicarea testului binomial	104
7.1.2. Interpretarea outputului	105
7.2. Testul χ^2 de ajustare sau potrivire (goodness of fit)	106
7.2.1. Prezentare generală	106
7.2.2. Aplicarea testului χ^2 de ajustare	106
7.2.3. Interpretarea outputului	108
Capitolul 8. Măsurile de asociere pentru tabele încrucișate (crosstabulations)	109
8.1. Testul χ^2 de asociere sau independență pentru analiza datelor categoricale	109
8.1.1. Prezentare generală	109
8.1.2. Aplicarea testului χ^2	109
8.1.3. Interpretarea outputului	112
8.1.4. Mărimea efectului	113
8.1.5. Prezentarea grafică a rezultatelor	114
8.1.6. Considerații finale	116
8.1.7. Prezentarea rezultatelor	117
8.2. Teste de asociere cu o variabilă nominală și una ordinală	117
8.2.1. Prezentare generală	117
8.2.2. Aplicarea testelor de asociere pentru o variabilă nominală și una ordinală	118

8.2.3. Interpretarea outputului	120
8.2.4. Considerații finale privind Lambda	121
8.3. Teste de asociere pentru variabile ordinale	124
8.3.1. Aplicarea testelor de asociere pentru variabile ordinale	124
8.3.2. Interpretarea outputului	126
Capitolul 9. Teste neparametrice pentru compararea a două eșantioane independente	128
9.1. Testul Mann-Whitney U pentru două eșantioane independente	128
9.1.1. Prezentare generală	128
9.1.2. Procedura de calcul a testului Mann-Whitney U	128
9.1.3. Aplicarea testului Mann-Whitney U	129
9.1.4. Interpretarea outputului	131
9.1.5. Prezentarea rezultatelor	133
9.1.6. Observații	134
9.2. Alte teste neparametrice pentru două eșantioane independente	134
Capitolul 10. Teste neparametrice pentru două eșantioane perechi	136
10.1. Testul Wilcoxon	136
10.1.1. Prezentare generală	136
10.1.2. Procedura de calcul a testului Wilcoxon	136
10.1.3. Aplicarea testului Wilcoxon	137
10.1.4. Interpretarea outputului	139
10.1.5. Prezentarea rezultatelor	140
10.2. Testul semnului (Sign Test)	140
10.2.1. Prezentare generală	140
10.2.2. Aplicarea testului semnului	140
10.2.3. Interpretarea outputului	141
10.3. Testul McNemar	142
10.3.1. Prezentare generală	142
10.3.2. Aplicarea testului McNemar	142
10.3.3. Interpretarea outputului	143
Capitolul 11. Teste neparametrice pentru mai mult de două eșantioane independente	145
11.1. Testul Kruskal-Wallis H	146
11.1.1. Prezentare generală	146
11.1.2. Aplicarea testului Kruskal-Wallis H	146
11.1.3. Interpretarea outputului	148
11.1.4. Prezentarea rezultatelor	151
11.2. Testul Jonckheere-Terpstra J	152
11.2.1. Prezentare generală	152
11.2.2. Aplicarea testului Jonckheere-Terpstra J	153
11.2.3. Interpretarea outputului	153
11.2.4. Prezentarea rezultatelor	155
11.3. Observații finale	155
Capitolul 12. Teste neparametrice pentru mai mult de două eșantioane perechi	157
12.1. Testul Friedman	157
12.1.1. Prezentare generală	157
12.1.2. Aplicarea testului Friedman	157
12.1.3. Interpretarea outputului	158
12.2. Testul Cochran Q	159
12.2.1. Prezentare generală	159
12.2.2. Aplicarea testului Cochran Q	160
12.2.3. Interpretarea outputului	160
Capitolul 13. ANOVA simplă (One-Way ANOVA)	162
13.1. Prezentare generală	162
13.2. Testele post hoc (neplanificate)	163

13.3. Testele de contrast sau comparațiile a priori (planificate)	165
13.4. Contraste polinomiale : analiza direcțională, de tendință (<i>trend analysis</i>)	168
13.5. Mărimea efectului în cazul testelor de contrast și al testelor post hoc	170
13.6. Aplicarea metodei One-Way ANOVA	170
13.7. Interpretarea outputului	172
13.8. Aplicarea testelor post hoc	175
13.9. Aplicarea testelor de contrast	177
13.9.1. <i>Aplicarea contrastelor nestandardizate neortogonale</i>	177
13.9.2. <i>Aplicarea contrastelor nestandardizate ortogonale</i>	179
13.9.3. <i>Aplicarea contrastelor standardizate</i>	180
13.10. Prezentarea rezultatelor	182
Capitolul 14. Analiza de varianță ANOVA factorială	184
14.1. Prezentare generală	184
14.2. Aplicarea metodei ANOVA factorială	186
14.3. Interpretarea outputului	187
14.4. Analiza efectelor principale	188
14.5. Analiza efectelor de interacțiune	189
14.6. Analiza efectului de interacțiune prin intermediul efectelor simple	190
14.6.1. <i>Analiza efectelor simple prin împărșirea bazei de date (Split File)</i>	191
14.6.2. <i>Analiza efectelor simple prin crearea unei noi variabile</i>	195
14.6.3. <i>Analiza efectelor simple prin folosirea sintaxelor</i>	198
14.7. Prezentarea rezultatelor	203
14.8. Analiza efectului de interacțiune prin intermediul contrastelor de interacțiune	204
14.8.1. <i>Prezentare generală</i>	204
14.8.2. <i>Analiza contrastelor de interacțiune</i>	206
14.8.3. <i>Contrastele de interacțiune când ambele variabile au mai mult de două nivele</i>	209
14.9. Observații finale	210
Capitolul 15. ANOVA simplă cu măsurători repetate	214
15.1. Prezentare generală	214
15.2. Aplicarea metodei ANOVA simplă cu măsurători repetate	215
15.3. Interpretarea outputului	218
15.4. Mărimea efectului	222
15.5. Prezentarea rezultatelor	223
Capitolul 16. ANOVA factorială cu măsurători repetate	224
16.1. Aplicarea ANOVA factorială cu măsurători repetate	224
16.2. Interpretarea outputului în ANOVA factorială cu măsurători repetate	227
16.3. Analiza efectelor principale	229
16.4. Analiza efectelor de interacțiune	232
16.4.1. <i>Analiza efectelor simple</i>	233
16.4.2. <i>Analiza contrastelor de interacțiune</i>	239
16.5. Calcularea mărimii efectelor	240
16.6. Prezentarea rezultatelor	241
Capitolul 17. ANOVA mixtă	242
17.1. Prezentare generală	242
17.2. Aplicarea metodei ANOVA mixtă	243
17.3. Interpretarea outputului	245
17.4. Analiza efectelor principale	247
17.5. Analiza efectului de interacțiune	249
17.5.1. <i>Analiza efectului de interacțiune prin intermediul efectelor simple</i>	249
17.5.2. <i>Analiza efectului de interacțiune prin intermediul contrastelor</i>	256
17.6. Mărimea efectelor în ANOVA mixtă	259
17.7. Prezentarea rezultatelor	260

Capitolul 18. ANCOVA (analiza de covarianță)	262
18.1. Prezentare generală	262
18.2. Aplicarea metodei ANCOVA simplă	263
18.3. Interpretarea outputului	265
18.4. Verificarea omogenității pantelor de regresie	267
18.4.1. Criteriul grafic de verificare a omogenității pantelor de regresie	267
18.4.2. Criteriul statistic de verificare a omogenității pantelor de regresie	269
18.5. Prezentarea rezultatelor	271
Capitolul 19. Regresia liniară simplă	274
19.1. Prezentare generală	274
19.2. Aplicarea regresiei liniare simple	275
19.3. Interpretarea outputului	278
19.4. Realizarea graficelor pentru regresia liniară simplă	280
19.5. Prezentarea rezultatelor	283
Capitolul 20. Regresia liniară multiplă	284
20.1. Prezentare generală	284
20.2. Aplicarea regresiei liniare multiple prin metoda ierarhică	285
20.3. Interpretarea outputului	290
20.4. Mărimea efectului	294
20.5. Verificarea asumpțiilor	294
20.6. Prezentarea rezultatelor	297
✓ Capitolul 21. Fidelitatea (Reliability Analysis)	299
21.1. Prezentare generală	299
21.2. Analiza fidelității scalelor	299
21.3. Interpretarea outputului	301
21.4. Considerații finale	304
✓ Capitolul 22. Analiza factorială exploratorie	305
22.1. Prezentare generală	305
22.2. Aspecte metodologice implicate în aplicarea analizei factoriale	306
22.2.1. Asumpții sau condiții ce trebuie îndeplinite pentru aplicarea analizei factoriale	306
22.2.2. Optimizarea modelului factorial prin designul cercetării	310
22.2.3. Metoda de extragere folosită	311
22.2.4. Metoda de rotație aplicată	312
22.2.5. Numărul factorilor de reținut. Reguli privind numărul factorilor extrași	314
22.3. Aplicarea analizei factoriale	317
22.4. Interpretarea outputului	323
22.5. Analiza comunalităților	331
22.6. Saturațiile factoriale și importanța acestora	331
22.7. Prezentarea rezultatelor	333
Rezolvarea exercițiilor	335
Analiza corelațională	335
Teste t parametrice	335
Teste neparametrice	336
ANOVA	337
Regresie liniară	339
Analiza fidelității scalelor	340
Analiza factorială	340
Bibliografie	341
Index tematic	343

Cuvânt înainte

Un educator bun trebuie nu numai să aibă experiență în domeniu, ci și să cunoască profilul faptului educativ, intimitatea procesului, specificitatea fenomenului pe care îl produce și îl tutează. Ne întrebăm, de bună seamă, cum se produce cunoașterea cu privire la educație, cum sporim experiența cognitivă în materie de îndrumare și formare. Să credem și în așa ceva? Sau e suficientă experiența acumulată în timp la catedră?

Aportul cognitiv într-o disciplină sau alta este asigurat atât printr-o inspecție atentă a realității de studiat, cât și prin prelucrarea adecvată a datelor provenite din practică. Există o cunoaștere imediată, de prim grad, asigurată prin intuirea corectă a fenomenologiei exterioare. Astfel, putem observa, la un moment dat sau în timp, reacțiile unui elev, performanțele lui la anumite materii, interacțiunea sa cu grupul etc. și ajungem la unele concluzii de care vom ține seama în continuare. Se remarcă însă și o cunoaștere mai subtilă, secundă, mediată de instrumentele cognitive, bazată pe deductibilitate și mecanisme interne, de ordin formal, ale instrumentelor de ordin epistemologic puse în joc. În fond, putem cunoaște în mod adecvat ceva uitându-ne bine la realitate, dar și procesând cât mai productiv datele la care avem acces, raportându-le unele la altele, la anumite scheme logice, exploatând cât mai mult potențialul cognitiv pe care-l poartă. Calitatea cunoașterii depinde de felul cum focalizăm „lumina” științei, dar și de felul cum „filtrăm” diversele nuanțe ale „reflecției” ei pe „ecranul” minții noastre, de diversele mecanisme de decodare, de inteligibilitate. Cunoașterea este dată de modul cum decupăm obiectul, dar și de instrumentul prin care îl cercetăm și interpretăm.

Asupra raportului cantitativ-calitativ în domeniul științelor educației s-au purtat discuții privind ponderea și importanța perspectivelor de abordare. Unii au pus accentul pe cuantificarea cât mai precisă a unor parametri, alții au dedus sau au impus anumite judecăți de valoare. Complementaritatea dintre măsurare și semnificare pare a fi de bun augur în orice demers de cunoaștere. Pretenția exactității este justificată dacă nu se ocultează multiplicitatea semnificațiilor posibile purtate de caleidoscopul realității interogate. Exactitatea nu coincide cu adevărul. Adevărul este mult mai polimorf, mai deschis și mai atent la dinamica realului. Exactitatea vine odată cu tipizarea și constrângerea lumii de a intra în cadrele raționalității. Nu tot ce este în lume „încapă” în carcasa minții noastre. De multe ori, rațiunea rămâne în urma evoluțiilor exterioare. Dar, fără claritatea ei, nu putem pătrunde în intimitatea lumii, nu o putem descifra și înțelege.

„Creșterea” epistemologică a unei științe se face pe mai multe căi: intuirea și observarea realității, reflectarea și poziționarea speculativă, producerea intenționată a unor fenomene caracteristice obiectului respectiv și decelarea acestora, verificarea unor ipoteze, măsurarea unor parametri, stabilirea unor regularități și legități, prelucrarea cantitativă a datelor obținute etc. Nu există o cale „regală”, unică, de sporire cognitivă; fiecare profil poate aduce o nouă lumină, poate dezvălui o nouă fațetă a fenomenului educativ. Analiza calitativă și analiza cantitativă se împletesc, se completează reciproc. Iar după ce observăm și măsurăm ceva, e obligatoriu să și semnificăm, să valorizăm, să dăm un sens rezultatelor cunoașterii la care am ajuns.

În domeniul științelor educației, lucrurile stau tot la fel. Există un arsenal metodologic de cunoaștere a faptelor educaționale, dar și strategii de prelucrare a informațiilor specifice. Printre aceste strategii un loc important îl ocupă metodele statistice.

Cartea de față, realizată de Adrian Vicențiu Labăr, vine cu un astfel de instrumentar metodic de prelucrare statistică a datelor culese din arealul educațional. Meritul tânărului pedagog rezidă în identificarea și explicitarea deosebit de clară a unor instrumente statistice de prelucrare a datelor cu

conținut psihopedagogic. Ne impresionează într-un mod plăcut coerența prezentării, pertinenta argumentativă și corelativitatea cadrului tehnic cu numeroase exemplificări și circumstanțieri. Chiar dacă limbajul este de strictă specialitate, chiar dacă autorul apelează la un cadru formalizat și abstractizat, dozajul, explicitările și nuanțările fac din carte un material „digerabil” pentru cel mai puțin familiarizat cu rigorile formale, pentru viitorul cercetător, pentru cadrul didactic doritor să acceseze o metodologie de prelucrare a datelor. Desigur, o astfel de învățare presupune o serie de achiziții prealabile (un minimal bagaj conceptual de ordin pedagogic, o competență informatică, cunoștințe elementare de matematică și logică). Dincolo de aspectul tehnic al lucrării, utilizatorul va avea bucuria descoperirii unor paliere noi de investigație și posibilități de coordonare a cunoașterii care generează un plus de cunoaștere. De altfel, autorul își sprijină demersul explicativ pe un bogat material ilustrativ (tabele, grafice, capturi de ecran), concretețea argumentativă dobândind un aspect tot mai evident. Nu mai vorbim despre activismul antrenat de excursul autorului prin propunerea unor teme de interogație, a unor activități posibile, a unor exerciții de realizat.

Lucrarea a urmărit să ofere o perspectivă mai degrabă practică, empirică, decât teoretică asupra metodelor de analiză a datelor utilizate cel mai frecvent în cercetarea pedagogică. Modalitatea de prezentare a fiecărei metode și tehnici statistice urmează o linie „didactică”, plecând de la o prezentare generală, urmând un exemplu de aplicare a metodei și de interpretare a rezultatelor, o modalitate de prezentare a acestora, iar în final, propunerea unor exerciții care să ofere un feedback complet cititorului.

Dacă în nenumărate cărți de specialitate destinate analizei datelor în științele sociale autorii prezentau doar anumite tehnici statistice de analiză a datelor, lucrarea lui Adrian Vicențiu Labăr caută să ofere o perspectivă cât mai amplă asupra celor mai frecvent întâlnite în cercetarea din câmpul educațional, precum și o prezentare de la simplu la complex a fiecărei tehnici statistice discutate. Tratarea completă a testelor parametrice, a testelor neparametrice, a tehnicilor ANOVA, a analizei de regresie, a analizei factoriale, precum și a modalităților de calcul al mărimii efectelor și prezentarea rezultatelor pentru fiecare tehnică statistică în parte sunt alte elemente care caută să răspundă nevoilor cititorului, în special celor ale cercetătorului în științele educației.

Adrian Vicențiu Labăr propune un instrument obligatoriu pentru cei care fac cercetare de teren în câmpul științelor educației. Desigur, unele artefacte sau secvențe metodologice se mai pot schimba sau rafina, dar ceea ce va rămâne constant este nevoia cercetătorului de a apela la un dispozitiv eficient care să-l ajute să deceleze datele observației empirice. Axiomă care străbate întreaga carte, ea însăși devenind o ilustrare elocventă a nevoii raportării deopotrivă la realitate, dar și la coerență, și sens!

Prof.univ.dr. Constantin Cucos

Introducere

Volumul de față reprezintă o trecere în revistă a metodelor și tehnicilor statistice de analiză a datelor utilizate cel mai frecvent în cercetarea pedagogică, urmărind două paliere de prezentare : de la cele mai simple, elementare metode la cele mai complexe, pe de o parte, iar pe de altă parte, în cadrul fiecărei metode, de la nivelul elementar până la aspectele cele mai complexe ale acesteia. Am urmărit să răspundem astfel diversității de metodologii de cercetare educațională prin oferirea unei palete largi de tehnici de analiză a datelor, din care cel interesat să poată opta pentru tehnica specifică tipului de cercetare realizat.

Am urmărit să prezentăm o perspectivă mai degrabă practică decât teoretică asupra acestor metode de analiză a datelor căutând să oferim de fiecare dată exemple de aplicare a acestor metode – exemple din arealul cercetării pedagogice – cu ajutorul cărora cititorul să poată gândi în termenii cercetării pedagogice, și nu ai celor din alte domenii conexe, familiarizându-l astfel cu metodologia analizei datelor specifice domeniului științelor educației.

În discutarea fiecărei metode statistice, linia urmată a fost una algoritmică, pedagogică, astfel încât cel interesat să înțeleagă cu ușurință fiecare metodă în parte. Am plecat de la o prezentare generală a fiecărei metode discutând scopul aplicării și condițiile ce trebuie îndeplinite, oferind deseori și exemple din arealul educațional. A urmat apoi o aplicație concretă în SPSS a respectivei metode și interpretarea outputului oferind în final exemple de prezentare a rezultatelor obținute. Am urmărit de asemenea să oferim și modalitatea de calculare a diferiților indicatori de mărime a efectului, aspect obligatoriu pentru orice publicare a rezultatelor obținute în revistele de specialitate. La finalul unor serii de capitole înrudite ale lucrării au fost propuse spre rezolvare exerciții, urmărind să oferim astfel un feedback optim acestuia.

Conținutul cărții este structurat pe mai multe părți. Într-o primă parte sunt discutate aspecte introductive, precum operațiile statistice de bază, realizarea graficelor, analiza răspunsurilor multiple și noțiuni de bază privind testarea ipotezelor (tipurile de ipoteze, tipurile de erori în testarea ipotezelor, verificarea normalității unei distribuții și prezentarea mărimii efectului). A doua parte tratează testele t parametrice și analiza corelațională. În a treia parte sunt discutate pe larg tehnicile neparametrice, fie că e vorba despre măsuri ale asocierii, fie despre tehnici de comparare a eșantioanelor. A patra parte este una mai generoasă, fiind destinată discutării în detaliu a metodei analizei de varianță ANOVA, respectiv tehnicilor ANOVA simplă, ANOVA factorială, ANOVA simplă cu măsurători repetate, ANOVA factorială cu măsurători repetate, ANOVA mixtă și ANCOVA, pentru tehnicile ANOVA factoriale fiind prezentate modalitățile de analiză a efectelor principale și a efectelor de interacțiune (acestea din urmă prin două metode, cea a efectelor simple și cea a contrastelor de interacțiune). În cadrul celei de-a cincea părți a fost prezentată analiza de regresie liniară simplă și multiplă. În fine, în cadrul ultimei părți au fost prezentate analiza de fidelitate și analiza factorială. Finalul cărții conține rezolvarea exercițiilor propuse pentru fiecare secțiune.

Pe tot parcursul lucrării am urmărit să oferim cititorului aplicații în care rezultatele obținute sunt semnificative statistic pentru ca acesta să aibă acces la modalitatea de interpretare a indicatorilor statistici obținuți.

Volumul se adresează studenților, masteranzilor, doctoranzilor și cercetătorilor din câmpul educațional, fiind însă util și publicului interesat din domenii conexe, precum psihologia, sociologia și chiar marketingul. Am căutat să răspundem prin acest volum la trei cerințe manifestate de publicul consumator din domeniu: punerea la dispoziție a bazelor de date, prezentarea elementelor de cel mai înalt nivel (în cadrul fiecărei tehnici SPSS) necesare pentru publicarea unor articole în domeniu (fără se neglijăm segmentul începătorilor și al celor de nivel mediu, ci dimpotrivă) și oferirea unei modalități de prezentare a rezultatelor obținute în acord cu standardele APA (Asociația Psihologilor Americani), forul cu cea mai mare autoritate în domeniul științelor sociale.

Bazele de date necesare pot fi descărcate de la adresa: <http://www.statisticasociala.ro/>, toate fiind elaborate de autor în scop didactic. Cum SPSS este o marcă înregistrată, programul poate fi achiziționat de la reprezentanța SPSS din România (www.spss.ro), fiind totodată disponibil studenților în majoritatea universităților din România. O alternativă pentru studenți este versiunea demonstrativă a programului, care poate fi descărcată de pe internet.

Capitolul 1. Introducere în SPSS

Prescurtarea SPSS a programului statistic pe care-l vom discuta în această carte provine de la numele englezesc al programului, *Statistical Package for the Social Sciences*, programul statistic cel mai utilizat pentru analiza datelor în științele sociale. Practic, orice program nou de analiză statistică a datelor care este scos pe piață e testat prin comparație cu SPSS (SPSS fiind programul de referință). Nu este de mirare astfel că SPSS a devenit indispensabil instituțiilor educaționale, instituțiilor publice sau firmelor private orientate spre realizarea de sondaje de opinie, studii de piață sau cercetare.

1.1. Realizarea unei baze de date

Să presupunem că am realizat o cercetare simplă în științele educației pentru a analiza percepția cadrelor didactice asupra descentralizării în educație. Un asemenea chestionar ar putea arăta precum cel din tabelul 1.1.

Tabelul 1.1. Chestionar privind descentralizarea în educație

a) Gen: 1. _____ Masculin; 2. _____ Feminin					
b) Vârsta _____ (în ani)					
c) Vechimea în învățământ _____ (în ani)					
d) Gradul didactic: 1. _____ Gradul I; 2. _____ Gradul II; 3. _____ Definitivat; 4. _____ Debutant					
e) Profesia: 1. _____ Educator; 2. _____ Învățător; 3. _____ Profesor					
f) Mediul de rezidență: 1. _____ Urban; 2. _____ Rural					
g) Următoarele afirmații vizează opinia dumneavoastră privind politicile de descentralizare în educație. Vă rugăm să le citiți cu atenție și să indicați măsura în care sunteți de acord cu fiecare dintre aceste afirmații, încercuind cifra corespunzătoare.					
(1) Descentralizarea permite o mai bună dezvoltare a instituțiilor de învățământ.					
1	2	3	4	5	6
total dezacord	dezacord	relativ dezacord	relativ de acord	de acord	total de acord
(2) Descentralizarea conduce la o creștere a responsabilității cadrelor didactice.					
1	2	3	4	5	6
total dezacord	dezacord	relativ dezacord	relativ de acord	de acord	total de acord

(3) Descentralizarea nu va determina cadrele didactice să se implice mai mult în procesul educativ.					
1	2	3	4	5	6
total dezacord	dezacord	relativ dezacord	relativ de acord	de acord	total de acord
(4) Descentralizarea conduce la o creștere a colaborării cu autoritățile locale.					
1	2	3	4	5	6
total dezacord	dezacord	relativ dezacord	relativ de acord	de acord	total de acord
(5) Descentralizarea va permite o mai bună promovare a imaginii școlii din care fac parte.					
1	2	3	4	5	6
total dezacord	dezacord	relativ dezacord	relativ de acord	de acord	total de acord

Să presupunem că am aplicat acest chestionar și dorim să introducem datele în SPSS ; pentru aceasta va trebui mai întâi să codificăm răspunsurile ca în tabelul 1.2.

Tabelul 1.2. Codificarea variabilelor pentru introducerea în SPSS

Variabila	Numele variabilei în SPSS	Codificare (ce vom trece în SPSS)
Gen	Genul subiecților	1 = masculin 2 = feminin
Vârsta	Vârsta subiecților	Vârsta în ani
Vechimea	Vechimea în învățământ	Vechimea în ani
Grad	Gradul didactic	1 = gradul I 2 = gradul II 3 = definitivat 4 = debutant
Profesia	Profesia cadrului didactic	1 = educator 2 = învățător 3 = profesor
Mediu	Mediul de rezidență	1 = urban 2 = rural
Item1	Descentralizarea permite o mai bună dezvoltare a instituțiilor de învățământ.	1 = total dezacord 2 = dezacord 3 = parțial dezacord 4 = parțial de acord 5 = de acord 6 = total de acord
Item2	Descentralizarea conduce la o creștere a responsabilității cadrelor didactice.	1 = total dezacord 2 = dezacord 3 = parțial dezacord 4 = parțial de acord 5 = de acord 6 = total de acord

Item3	Descentralizarea nu va determina cadrele didactice să se implice mai mult în procesul educativ.	1 = total dezacord 2 = dezacord 3 = parțial dezacord 4 = parțial de acord 5 = de acord 6 = total de acord
Item4	Descentralizarea conduce la o creștere a colaborării cu autoritățile locale	1 = total dezacord 2 = dezacord 3 = parțial dezacord 4 = parțial de acord 5 = de acord 6 = total de acord
Item5	Descentralizarea va permite o mai bună promovare a imaginii școlii din care fac parte.	1 = total dezacord 2 = dezacord 3 = parțial dezacord 4 = parțial de acord 5 = de acord 6 = total de acord

Dacă în continuare am aplicat acest chestionar pe un eșantion de 5 subiecți cadre didactice, datele obținute pe coloane ar putea arăta astfel :

Tabelul 1.3. Datele obținute, pe coloane

nrsb	gen	vârsta	vechime	grad	profesi e	mediu	Item1	Item2	Item3	Item4	Item5
1	2	45	20	2	2	1	3	4	5	4	4
2	2	43	23	1	3	1	5	6	2	6	6
3	1	50	28	2	3	1	4	5	3	5	5
4	2	55	33	2	1	2	2	2	5	4	3
5	2	28	10	3	2	1	6	5	2	6	5

Observați că în tabelul 3 am introdus o nouă variabilă, „nrsb”, reprezentând numărul de ordine al fiecărui subiect. Prin urmare, având 100 de subiecți pe care am aplicat chestionarul, vom numerota chestionarele de la 1 la 100 și, astfel, fiecare subiect va obține un număr de ordine. Dacă ar fi să ne referim la subiectul cu numărul 2, observăm că acesta este de gen feminin, are vârsta de 43 de ani, 23 de ani vechime în învățământ, gradul didactic 1, este profesor, din mediul urban și a încercuit cifra 5 la itemul 1 („de acord”), cifra 6 la itemul 2 („total de acord”), cifra 2 la itemul 3 („dezacord”), cifra 6 la itemul 4 („total de acord”) și cifra 6 la itemul 5 („total de acord”). În continuare va trebui să realizăm baza de date în SPSS.

Deschidem programul SPSS. Programul dispune de două modalități de vizualizare a bazei de date: *Data View*, permițând vizualizarea datelor, și *Variable View*, permițând vizualizarea variabilelor (colțul din stânga-jos).

38			
39			
40			

◀ ▶ Data View Variable View

Va trebui mai întâi să definim variabilele, prin urmare facem clic pe *Variable View*. Fereastra din SPSS va arăta astfel :

Untitled - SPSS Data Editor										
File Edit View Data Transform Analyze Graphs Utilities Window Help										
	Name	Type	Width	Decimals	Label	Values	Missing	Columns	Align	Measure
1										
2										
3										
4										
5										
6										

În câmpul *Name* vom trece denumirea variabilei (maximum opt caractere), în câmpul *Label* vom trece denumirea variabilei în limbaj extins (putem scrie și o „poveste” dacă vrem, SPSS oferind spațiul respectiv), în câmpul *Values* vom codifica variabilele precizând ce înseamnă fiecare cifră, iar în câmpul *Measure* putem alege să specificăm tipul de scală pe care este măsurată variabila în cauză.

Să luăm de exemplu variabila *gen*. Vom trece în câmpul *Name* „gen”, în câmpul *Label* „genul subiecților”, iar în câmpul *Values* va trebui să specificăm că valoarea „1” reprezintă subiecții de gen masculin și valoarea „2” pe cei de gen feminin. Facem clic pe meniul *Variable* și ni se va deschide un nou câmp de lucru.

Value Labels

Value Labels

Value: 2

Value Label: feminin

Add 1.00 = "masculin"

Change

Remove

OK

Cancel

Help


Vom trece în câmpul *Value* mai întâi cifra „1”, iar în câmpul *Value Label* eticheta pentru această valoare (în cazul de față, *masculin*), ce reprezintă aceasta, apoi clic pe

butonul *Add*, revenim în câmpul *Value* unde trecem valoarea „2”, iar în câmpul *Value Label* trecem *feminin*, clic pe butonul *Add* și clic *OK*. Astfel, am definit valorile variabilei gen. Vom proceda similar pentru toate variabilele.

După ce am terminat de definit toate variabilele, baza de date va trebui să arate astfel:

baza_date SPSS Data Editor

File Edit View Data Transform Analyze Graphs Utilities Window Help




	Name	Type	Width	Decimals	Label	Values
1	nrsb	Numeric	8	2		None
2	gen	Numeric	8	2	genul subiectilor	{1,00, masculin)...
3	varsta	Numeric	8	2	varsta	None
4	vechime	Numeric	8	2	vechimea in invatam	None
5	grad	Numeric	8	2	gradul didactic	{1,00, gradul I)...
6	profesie	Numeric	8	2	profesia	{1,00, educator)...
7	mediu	Numeric	8	2	mediu	{1,00, mediul urban)...
8	item1	Numeric	8	2	Descentralizarea per	{1,00, total dezacord)...
9	item2	Numeric	8	2	Descentralizarea con	{1,00, total dezacord)...
10	item3	Numeric	8	2	Descentralizarea nu l	{1,00, total dezacord)...
11	item4	Numeric	8	2	Descentralizarea con	{1,00, total dezacord)...
12	item5	Numeric	8	2	Descentralizarea va	{1,00, total dezacord)...

Mai departe va trebui să introducem datele obținute pentru fiecare subiect. Vom face clic pe *Data View* (colțul din stânga-jos) pentru a putea vizualiza datele din baza de date și vom introduce valorile din tabelul 3. Baza de date va arăta după cum urmează:

baza_date SPSS Data Editor

File Edit View Data Transform Analyze Graphs Utilities Window Help



11:

	nrsb	gen	varsta	vechime	grad	profesie	mediu	item1	item2	item3	item4	item5
1	1,00	2,00	45,00	20,00	2,00	2,00	1,00	3,00	4,00	5,00	4,00	4,00
2	2,00	2,00	43,00	23,00	1,00	3,00	1,00	5,00	6,00	2,00	6,00	6,00
3	3,00	1,00	60,00	28,00	2,00	3,00	1,00	4,00	5,00	3,00	5,00	5,00
4	4,00	2,00	55,00	33,00	2,00	1,00	2,00	2,00	5,00	5,00	4,00	3,00
5	5,00	2,00	28,00	10,00	3,00	2,00	1,00	6,00	5,00	2,00	6,00	5,00
6												
7												
8												

Nu uitați să salvați în final baza de date nou creată. În ceea ce ne privește, am salvat aceasta bază de date cu denumirea *baza_date* iar cei interesați o vor putea consulta.

1.2. Operații statistice de bază. Tabele de frecvență

Analiza tabelor de frecvență este utilă din mai multe perspective: a) ne ajută în descrierea compoziției eșantionului pe care s-a desfășurat cercetarea; b) poate fi o operație statistică utilă pentru descrierea procentelor de subiecți care au ales diferite forme de

răspuns la un item ; c) în verificarea bazei de date, deseori putând exista erori, cifre extreme introduse din greșeală și care ar conduce fie la rezultate eronate, fie la rezultate aberante în urma analizelor statistice.

1.2.1. Tabele de frecvență. Ilustrarea compoziției lotului de subiecți


Pentru ilustrarea compoziției lotului de subiecți participanți într-o cercetare trebuie să precizăm numărul de subiecți și eventual procentul acestora în funcție de câteva variabile de bază luate în calcul precum *genul*, *mediul de rezidență*, *gradul didactic*, *ciclul de învățământ*, *clasa*, *profesia* etc.

Deschidem fișierul *frecvente_1*. Să presupunem că subiecții participanți într-o cercetare au fost studenți din cadrul mai multor facultăți, de gen masculin și feminin, provenind din mediul urban sau rural. Ne va interesa să prezentăm o descriere a lotului de subiecți în funcție de variabilele *facultate*, *gen* și *mediu*. Călea în SPSS este *Analyze* → *Descriptive Statistics* → *Frequencies*.

The screenshot shows the SPSS Data Editor window for 'frecvente_1'. The 'Analyze' menu is open, and the path 'Descriptive Statistics' → 'Frequencies...' is highlighted. The data table below shows the structure of the dataset with columns for 'facult' and 'mediu'.

	facult	mediu
1	1	
2	1	
3	1	
4	1	
5	1	
6	1	
7	1	
8	1	
9	1	2
10	1	1

✗ Trecem variabilele *facultate*, *mediu* și *gen* în câmpul *Variable(s)* și apăsăm OK.



Rezultatele obținute sunt prezentate în continuare. Primul tabel, *Statistics*, prezintă pentru fiecare dintre cele trei variabile numărul de cazuri (subiecți) valide (352 în cazul de față), precum și numărul de valori lipsă (0 în cazul de față). Să presupunem că dintre cei 352 de subiecți, doi nu și-ar fi prezentat mediul de rezidență; în acest caz, în cadrul coloanei *mediu de proveniență* am fi observat 350 de cazuri valide și două cazuri lipsă.

Statistics

		facultatea	mediul de provenienta	gen
N	Valid	352	352	352
	Missing	0	0	0

Următorul tabel, *facultatea*, prezintă frecvențele observate (numărul de subiecți) pentru fiecare facultate în coloana *Frequency*, procentul de subiecți din totalul subiecților pentru fiecare facultate în coloana *Percent*, procentul valid de subiecți pentru fiecare facultate din totalul subiecților în coloana *Valid Percent*, iar în ultima coloană (*Cumulative Percent*) procentele cumulate, adunate de la o treaptă la următoarea a variabilei *facultate*.

facultatea

	Frequency	Percent	Valid Percent	Cumulative Percent
Valid filosofie	30	8,5	8,5	8,5
geografie	36	10,2	10,2	18,8
științe economice	24	6,8	6,8	25,6
biologie	38	10,8	10,8	36,4
matematica	71	20,2	20,2	56,5
filologie	46	13,1	13,1	69,6
fizica	69	19,6	19,6	89,2
istorie	38	10,8	10,8	100,0
Total	352	100,0	100,0	

Observăm astfel că lotul de subiecți conține 30 de studenți de la Facultatea de Filosofie, reprezentând 8,5% din totalul de subiecți (352), 36 de studenți de la Facultatea de Geografie, reprezentând 10,2% din total, 24 de studenți de la Facultatea de Științe Economice, reprezentând 6,8% din total etc. Deoarece în cazul acestei variabile nu avem valori lipsă (fiecare dintre subiecți precizând facultatea pe care o urmează), procentele din coloana a treia sunt aceleași cu procentele valide din coloana a patra. În ultima coloană sunt prezentate procentele cumulate: studenții de la Filosofie reprezintă 8,5% din total, studenții de la Filosofie plus cei de la Geografie reprezintă 18,8% din total (au fost adunate procentele pentru fiecare dintre cele două facultăți, respectiv 8,5% + 10,2%, iar rezultatul rotunjit), studenții de la Filosofie, Geografie și Științe economice reprezintă 25,6% din total etc.

Din tabelul *mediu de proveniență* constatăm că 238 dintre studenți sunt din mediul urban și reprezintă 67,6% din total, iar 114 studenți sunt din mediul rural și reprezintă 32,4% din totalul de subiecți.

mediul de provenienta


	Frequency	Percent	Valid Percent	Cumulative Percent
Valid urban	238	67,6	67,6	67,6
rural	114	32,4	32,4	100,0
Total	352	100,0	100,0	

În fine, din tabelul *gen* constatăm că 258 dintre studenți sunt de gen feminin și reprezintă 73,3% din total și 94 sunt de gen masculin, reprezentând 26,7% din total.


gen

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	feminin	258	73,3	73,3	73,3
	masculin	94	26,7	26,7	100,0
	Total	352	100,0	100,0	

Dacă de exemplu intenționăm să aflăm distribuția variabilei *gen* în funcție de variabila *mediu* (din totalul studenților din mediul urban, câți sunt de gen masculin și câți de gen feminin și, la fel, din totalul studenților din mediul rural, câți sunt de gen masculin și câți de gen feminin), calea în SPSS va fi: Analyze → Descriptive Statistics → Crosstabs.



Vom trece variabila *mediu* în câmpul *Row(s)*, variabila *gen* în câmpul *Column(s)*, activăm butonul *Cells*, iar aici lăsăm bifată opțiunea *Observed* și bifăm opțiunea *Row*, clic *Continue* și clic *OK*.



Datele care ne interesează le regăsim în tabelul Crosstabulation de mai jos.

mediul de proveniența * gen Crosstabulation

			gen		Total
			feminin	masculin	
mediul de provenienta	urban	Count	177	61	238
		% within mediul de provenienta	74,4%	25,6%	100,0%
	rural	Count	81	33	114
		% within mediul de provenienta	71,1%	28,9%	100,0%
Total		Count	258	94	352
		% within mediul de provenienta	73,3%	26,7%	100,0%

Vom citi informațiile din tabel pe linii. Observăm că, din totalul de 238 de studenți din mediul urban, 177 (sau 74,4%) sunt de gen feminin, iar 61 (sau 25,6%) sunt de gen masculin. De asemenea, din totalul de 114 subiecți din mediul rural, 81 (sau 71,1%) sunt de gen feminin și doar 33 (sau 28,9%) sunt de gen masculin.


1.2.2. Tabele de frecvență. Analiza răspunsurilor subiecților la un item

Într-un studiu desfășurat pe un lot de 50 de cadre didactice ne-a interesat să analizăm satisfacția acestora față de profesia de cadru didactic prin intermediul a trei itemi:

1. Meseria mea de profesor este excelentă.
2. Până acum am obținut lucruri importante în meseria mea ca profesor.
3. Dacă ar fi să-mi aleg cariera din nou, nu aș schimba aproape nimic.

Variantele de răspuns au fost: 1 = „total dezacord”, 2 = „dezacord”, 3 = „nu știu”, 4 = „de acord” și 5 = „total de acord”.

Deschideți fișierul *satisfacție*. Vom analiza răspunsurile cadrelor didactice la acești itemi prin intermediul analizei de frecvențe.



Vom analiza în continuare rezultatele obținute. În ceea ce privește itemul „Meseria mea de profesor este excelentă”, 4% dintre subiecți se declară în dezacord total, 10% dintre subiecți se declară în dezacord, 16% dintre subiecți aleg răspunsul „nu știu”, 32% dintre subiecți se declară de acord și 38% dintre subiecți se declară total de acord. Adunând răspunsurile favorabile, observăm că 70% dintre cadrele didactice investigate se declară de acord sau total de acord cu afirmația „Meseria mea de profesor este excelentă”.

Meseria mea de profesor este excelenta

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	total dezacord	2	4,0	4,0	4,0
	dezacord	5	10,0	10,0	14,0
	nu știu	8	16,0	16,0	30,0
	de acord	16	32,0	32,0	62,0
	total de acord	19	38,0	38,0	100,0
	Total	50	100,0	100,0	

În ceea ce privește itemul „Până acum am obținut lucruri importante în meseria mea de profesor”, 8% dintre subiecți sunt în dezacord total, 12% dintre subiecți se declară în dezacord, 16% dintre subiecți declară că nu știu, nu pot aprecia, 40% dintre subiecți se declară de acord și 24% dintre subiecți se declară total de acord. Dacă adunăm procentele privind răspunsurile favorabile, vom obține că 64% dintre cadrele didactice investigate consideră că au obținut, au realizat lucruri importante în meseria de profesori.

Pana acum am obtinut lucruri importante in meseria mea ca profesor.

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	total dezacord	4	8,0	8,0	8,0
	dezacord	6	12,0	12,0	20,0
	nu stiu	8	16,0	16,0	36,0
	de acord	20	40,0	40,0	76,0
	total de acord	12	24,0	24,0	100,0
	Total	50	100,0	100,0	

În fine, analizând răspunsurile subiecților la itemul „Dacă ar fi să-mi aleg cariera din nou, nu aş schimba aproape nimic”, 12% dintre subiecți se declară în dezacord total, 12% se declară în dezacord, 20% declară că nu știu, nu se pot decide, 20% dintre subiecți sunt de acord și 36% se declară total de acord. Analizând răspunsurile la acest item, observăm că 24% dintre subiecți ar dori să-și schimbe cariera aleasă, 20% nu se pot decide, iar 56% dintre subiecți consideră că ar alege aceeași cariera.

Daca ar fi sa-mi aleg cariera din nou, nu as schimba aproape nimic

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	total dezacord	6	12,0	12,0	12,0
	dezacord	6	12,0	12,0	24,0
	nu stiu	10	20,0	20,0	44,0
	de acord	10	20,0	20,0	64,0
	total de acord	18	36,0	36,0	100,0
	Total	50	100,0	100,0	

Răspunsurile pot fi sintetizate sub forma următorului tabel :

Tabelul 1.4. Răspunsurile procentuale ale cadrelor didactice la itemii privind satisfacția la locul de muncă

Itemi	Variante de răspuns				
	total dezacord	dezacord	nu știu	de acord	total de acord
1. Meseria mea de profesor este excelentă	4%	10%	16%	32%	38%
2. Până acum am obținut lucruri importante în meseria mea ca profesor	8%	12%	16%	40%	24%
3. Dacă ar fi să-mi aleg cariera din nou, nu aş schimba aproape nimic	12%	12%	20%	20%	36%

1.2.3. Tabele de frecvență. Verificarea bazei de date


Deseori, analiza tabelelor de frecvență ne poate ajuta atunci când verificăm existența unor greșeli în baza de date cauzate de neatenția celui care a realizat-o. Să presupunem că la un item măsurat pe o scală Likert în cinci trepte, cel care face baza de date trece din greșeală o valoare de „55” în loc să treacă valoarea „5”. O asemenea greșeală ne poate costa ulterior atunci când adunând itemul respectiv cu alți itemi care măsoară același lucru și calculând media vom obține o valoare cu mult peste cea reală, fapt ce va distorsiona rezultatele obținute. În asemenea cazuri, definirea unei variabile precum „numărul de ordine al subiectului” în baza de date ne va ajuta să identificăm în cazul cărui subiect a fost realizată greșeala, aceasta urmând a fi remediată.

Deschidem fișierul *satisfacție_1*. Realizând analiza de frecvențe pentru cei trei itemi, vom constata că în cazul itemului „Până acum am obținut lucruri importante în meseria mea ca profesor” (itemul sat2) există un răspuns extrem, „45” datorat greșelii celui care a introdus datele în baza de date.


Pana acum am obtinut lucruri importante in meseria mea ca profesor.

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	total dezacord	4	8,0	8,0	8,0
	dezacord	6	12,0	12,0	20,0
	nu stiu	8	16,0	16,0	36,0
	de acord	19	38,0	38,0	74,0
	total de acord	12	24,0	24,0	98,0
	45,00	1	2,0	2,0	100,0
	Total	50	100,0	100,0	

În această situație va trebui să identificăm unde anume în baza de date apare acest răspuns. Pentru aceasta vom proceda la o ordonare descendentă a bazei de date în funcție de valorile itemului sat2. Călea în SPSS este: *Data → Sort Cases*.



Trecem variabila sat2 („Până acum am obținut lucruri importante în meseria mea ca profesor”) în câmpul din dreapta *Sort by* : , bifăm mai jos opțiunea *Descending* și clic OK. Am fi putut lăsa bifată opțiunea de sortare ascendentă, crescătoare a datelor (*Ascending*), însă valoarea extremă pe care o căutăm va fi prezentată în partea de jos a bazei de date, iar la un număr mare de subiecți ar putea fi puțin incomod. Oricum, ambele opțiuni ne pot ajuta să identificăm în cazul cărui subiect din baza de date apare valoarea „45” în cadrul itemului sat1.



Baza de date va arăta ca în imaginea de mai jos. Observăm că valoarea „45” la itemul sat2 corespunde subiectului cu numărul de ordine 47. Ceea ce va trebui să facem acum este să căutăm chestionarul completat de către subiectul 47 (presupunând că am numerotat inițial chestionarele completate de fiecare subiect, acordându-le numere de ordine) și să verificăm răspunsul subiectului 47 la itemul sat2. Vom găsi că subiectul 47 a încercuit la itemul sat2 valoarea 4, de exemplu, și vom înlocui în baza de date valoarea 45 cu 4, rezolvând astfel problema apărută.

satisfactie_1 SPSS Data Editor

File Edit View Data Transform Analyze Graphs Utilities Window Help


6: sat1 5

	nrsub	gen	grad	profesie	mediu	sat1	sat2	sat3
1	47,00	2	2	1	2	4,00	45,00	4,00
2	8,00	1	3	1	1	5,00	5,00	5,00
3	11,00	2	3	2	1	5,00	5,00	5,00
4	13,00	2	1	3	2	5,00	5,00	5,00


1.3. Operații statistice introductive. Calcularea indicatorilor statistici de bază pentru variabile cantitative: media, mediana etc.

Deseori în cercetările realizate ne interesează să aflăm anumiți indicatori statistici pentru variabilele cantitative analizate precum media, mediana, abaterea standard etc. Există mai multe căi în SPSS pentru obținerea acestor indicatori.

Deschidem fișierul *Corelație*. Vom urma în SPSS calea: *Analyze* → *Descriptive Statistics* → *Frequencies*.



Trecem variabilele cantitative *leadership* și *creativitate* în câmpul din dreapta, *Variable(s)*. Deoarece variabilele sunt cantitative, nu ne va interesa afișarea tabelului de frecvențe. Prin urmare vom anula opțiunea din stânga-jos *Display frequency tables*. Activăm butonul *Statistics*. Aici avem mai multe opțiuni la care putem apela.



- În câmpul din dreapta-sus există câteva opțiuni pentru împărțirea unei distribuții într-un număr de părți egale. Nu vom selecta nimic aici.

- În câmpul din stânga-sus, *Central Tendency*, sunt prezentați o serie de indicatori ai tendinței centrale: *Mean* (media), *Median* (mediana), *Mode* (modul), *Sum* (suma tuturor observațiilor). Deoarece ne interesează calcularea doar a mediei și mediane variabilelor analizate, vom bifa *Mean* și *Median*.
- În câmpul *Dispersion* sunt o serie de indicatori ai dispersiei: *Std. Deviation* (abaterea standard), *Variance* (varianța), *Range* (amplitudinea varianței), *Minimum* (valoarea minimă), *Maximum* (valoarea maximă) și *S.E. Mean* (eroarea medie de selecție). De aici ne interesează să calculăm abaterea standard, varianța, valorile minime și maxime pentru variabilele selectate.
- În câmpul *Distribution* selectăm indicatorii de boltire (*Kurtosis*) și de asimetrie (*Skewness*) pentru distribuția fiecărei variabile, apoi clic *Continue* și clic *OK*.

Statistics

		leadership	creativitate
N	Valid	104	104
	Missing	0	0
Mean		123,38	112,58
Median		122,00	114,50
Std. Deviation		23,62	21,31
Variance		557,93	454,13
Skewness		-,006	-,458
Std. Error of Skewness		,237	,237
Kurtosis		-,770	-,075
Std. Error of Kurtosis		,469	,469
Minimum		77	46
Maximum		170	152


Rezultatele sunt prezentate în tabelul Statistics. Observăm că pentru variabila *leadership*, media = 123,38, mediana = 122,00, abaterea standard = 23,62, varianța = 557,93, valoarea minimă este 77, valoarea maximă este 170, indicatorul de asimetrie *Skewness* = - 0,006, indicatorul de boltire este *Kurtosis* = - 0,770; mai sunt prezentate erorile standard pentru indicatorii de asimetrie și boltire. În mod similar, sunt prezentați acești indicatori și pentru variabila *creativitate*.

1.4. Operații statistice introductive. Calcularea indicatorilor statistici de bază pentru variabile cantitative, în cazul unor distribuții bivariate


Deseori, ne va interesa calcularea unor indicatori statistici ai variabilelor cantitative diferențiat în funcție de nivelele unei alte variabile, de regulă nominale sau ordinale. Să presupunem că într-o cercetare privind influența stilului parental asupra motivației

intrinseci a elevilor ne interesează să aflăm dacă elevii provenind din familii ai căror părinți adoptă un stil parental democratic au o motivație intrinsecă mai dezvoltată comparativ cu copiii provenind din familii ai căror părinți adoptă un stil parental autoritar.

Deschidem fișierul *independent_1_test*. Să presupunem că ne interesează să calculăm media și mediana variabilei *motivație intrinsecă*, diferențiat în funcție de variabila *stil parental: democratic versus autoritar*. Există mai multe căi în SPSS pentru obținerea acestor rezultate. Călea pe care alegem să o urmăm este: *Analyze → Reports → Case Summaries*.



Trecem variabila cantitativă *motivație intrinsecă* în câmpul *Variable(s)* iar variabila nominală *stil parental* în câmpul *Grouping Variable(s)*. Anulăm opțiunea din stanga jos *Display cases* și activăm butonul *Statistics*. În noua fereastră, *Summary Report: Statistics*, în câmpul din dreapta *Statistics* dispunem de mai mulți indicatori statistici pentru variabila cantitativă *motivație*: vom selecta doar media și mediana și le vom trece în câmpul din dreapta, *Cell Statistics*, clic *Continue* și *OK*.



Rezultatele care ne interesează sunt prezentate în tabelul Case Summaries. Observăm că pentru elevii provenind din familii cu un stil parental democratic media la variabila *motivație intrinsecă* este 35,17, iar mediana este 36,00. De asemenea, pentru elevii provenind din familii cu un stil parental autoritar, media la variabila *motivație intrinsecă* este 33,44, iar mediana este 33,00. Prin urmare, media și mediana la variabila *motivație intrinsecă* pentru elevii beneficiind de un stil parental democratic sunt superioare mediei și medianei la aceeași variabilă pentru copiii beneficiind de un stil parental autoritar.

Case Summaries

motivație intrinsecă

stil parental	N	Mean	Median
stil democratic	42	35,17	36,00
stil autoritar	34	33,44	33,00
Total	76	34,39	34,00

Capitolul 2. Reprezentarea grafică a variabilelor


Deseori este utilă reprezentarea grafică a distribuției variabilelor fie individual, fie în funcție de o altă variabilă.

2.1. Prezentarea grafică a distribuției de frecvențe pentru ilustrarea compoziției lotului de subiecți


Pe lângă prezentarea distribuției de frecvențe a lotului de subiecți pe care s-a realizat cercetarea după diferite variabile precum gen, mediu, ciclu de învățământ etc., este utilă și ilustrarea grafică în funcție de astfel de variabile deoarece evidențiază mai clar compoziția lotului de subiecți. Genul de grafice indicate în asemenea cazuri sunt cele sub formă de cerc.

2.1.1. Ilustrarea întregului lot de subiecți în funcție de anumite variabile categoriale


Deschidem fișierul *satisfacție*. Dorim să ilustrăm compoziția lotului de subiecți în funcție de variabilele *gen*, *grad didactic*, *profesie* și *mediu*. Calea în SPSS este : *Graphs* → *Pie*.



Vom realiza mai întâi reprezentarea grafică a lotului de subiecți în funcție de variabila *gen*. Trecem variabila *gen* din câmpul din partea stângă în dreapta în câmpul *Define Slices by* :, apoi clic *OK*.




Graficul inițial va arăta astfel :




După cum se observă, numărul subiecților de gen feminin este mai mare comparativ cu al celor de gen masculin. Dacă dorim însă ca graficul să afișeze și procentele de subiecți pentru fiecare categorie a variabilei *gen*, va trebui să facem dublu-clic


pe grafic. Se va deschide o nouă fereastră, *Chart1 – SPSS Chart Editor* care ne permite să intervenim asupra graficului. Urmăm calea *Chart → Option*.



În noua fereastră, *Pie Options*, vom bifa opțiunea *Percents*, apoi clic *OK*.




În continuare vom închide fereastra *Chart1 – SPSS Chart Editor*. Graficul va arăta acum astfel :



Conform graficului, din totalul de subiecți, 58% sunt de gen feminin, iar 42% sunt de gen masculin.

Urmând aceleași proceduri pentru a ilustra compoziția lotului de subiecți după variabila *grad didactic*, vom obține graficul de mai jos.




Constatăm că, din totalul cadrelor didactice investigate, 10% sunt debutante, 30% au definitivatul dat, 28% au gradul II și 32% au gradul I.

2.1.2. Ilustrarea unei părți a lotului de subiecți în funcție de anumite variabile categoriale


Dacă într-o cercetare realizată pe elevi olimpici și nonolimpici ne interesează să ilustrăm compoziția loturilor de olimpici și nonolimpici în funcție de variabila *gen*, va trebui să procedăm puțin diferit. Așadar, dorim să obținem un grafic pentru elevii olimpici din care să vedem câți sunt de gen masculin și câți de gen feminin și același tip de grafic pentru elevii nonolimpici.

Deschidem baza de date *olimpici*. Mai întâi vom împărți baza de date în două, în funcție de variabila *olimpici* prin procedura *Split File* și ulterior vom realiza graficul sub formă de cerc, după variabila *gen*; SPSS ne va furniza două grafice, unul pentru lotul de olimpici și unul pentru lotul de nonolimpici.

Pentru procedura *Split File*, calea în SPSS este *Data → Split File*.




Selectăm *Organize output by groups* și trecem variabila *olimpiadă* în câmpul din dreapta, *Groups Based On*, apoi clic OK.




Current Status: Analysis by groups is off.

În continuare vom urma calea *Graphs* → *Pie* pentru a realiza graficul în funcție de variabila gen. Graficele obținute sunt prezentate mai jos.



Constatăm că, dintre elevii nonolimpici, 37,5% sunt de gen masculin și 62,5% sunt de gen feminin.




În ceea ce privește elevii olimpici, 40% sunt de gen masculin și 60% sunt de gen feminin.

2.2. Prezentarea grafică a distribuției de frecvențe în general


Atunci când urmărim reprezentarea grafică a unei distribuții de frecvențe care nu ține de variabile ce definesc compoziția lotului de subiecți vom utiliza prezentări grafice sub formă de bare.

2.2.1. Grafice pentru distribuții de frecvențe în cazul unei singure variabile nominale sau ordinale


Deschidem fișierul *satisfactie*. Vrem să ilustrăm grafic procentele subiecților care au ales una dintre variantele de răspuns la itemul „Meseria mea de profesor este excelentă”. Călea în SPSS este : *Graphs* → *Bar*.




În noua fereastră deschisă selectăm opțiunea *Simple*, iar în câmpul *Data in Chart Are* ne asigurăm că avem selectată opțiunea *Summaries for groups of cases*. Apoi clic *Define*.



În noua fereastră deschisă, *Define Simple Bar : Summaries for Groups of Cases*, trecem itemul sat1 (*Meseria mea de profesor este excelentă*) din partea stângă în câmpul din dreapta, *Category Axis*, selectăm opțiunea *% of cases* din dreapta-sus și clic *OK*.



Graficul obținut inițial este prezentat mai jos.




Dacă dorim să afișăm grafic și procentul efectiv al respondenților care au optat pentru una dintre cele cinci variante de răspuns, vom face dublu-clic pe grafic și se

va deschide o nouă fereastră, *Chart1 - SPSS Chart Editor*. Aici vom face clic pe butonul  ..

Se va deschide o nouă fereastră, *Bar Label Styles*, în care vom selecta opțiunea *Framed*; clic pe butonul *Apply All*, apoi clic *Close* și închidem fereastra *Chart1 - SPSS Chart Editor*.



Noul grafic este prezentat mai jos. Observăm că 4% dintre subiecți au ales varianta de răspuns „total dezacord”, 10% au ales varianta „dezacord”, 16% au ales varianta „nu știu”, 32% „de acord” și 38% „total de acord”.




Meseria mea de profesor este excelenta

2.2.2. Grafice pentru distribuții de frecvențe în cazul încrucișării a două variabile nominale sau ordinale

Presupunem că am realizat un experiment pentru a verifica influența repetării unei serii de zece cifre asupra memorării acestora de către subiecți. Pentru primul grup experimentatorului va citi cifrele o singură dată și le va cere subiecților să le repete, pentru al doilea grup experimentatorului va citi cifrele și apoi le va repeta o singură dată, iar ulterior le va cere subiecților să le reproducă. Pe baza numărului de cifre reproduse corect de către subiecți, experimentatorul îi va împărți pe aceștia în două grupe : cu rezultate bune *versus* cu rezultate slabe. Variabila independentă va fi variabila *repetare* (două categorii : da *versus* nu), iar variabila independentă va fi variabila *memorie* (două categorii : rezultate bune *versus* rezultate slabe).

Deschideți fișierul *repetare_cifre*. Calea în SPSS este : *Graphs* → *Bar*. În fereastra deschisă selectăm opțiunea *Clustered*, iar în câmpul *Data in Chart Are* ne asigurăm că este selectată opțiunea *Summaries for groups of cases* ; apoi clic *Define*.



În fereastră deschisă, *Define Clustered Bar : Summaries for Groups of Cases*, trecem variabila *memorie cifre* în câmpul din dreapta *Category Axis*, apoi variabila *repetare* în câmpul *Define Clusters by :*, ne asigurăm că este selectată opțiunea *N of cases* din partea de sus a ferestrei și facem clic *OK*.

Define Clustered Bar: Summaries for Groups of Cases

Bars Represent:

☒ N of cases ☐ % of cases

☐ Cum. n of cases ☐ Cum. % of cases

☐ Other summary function

Variable: _____

Change Summary...

Category Axis:

☒ memorie cifre [memori]

Define Clusters by:

☒ repetare [repetare]

Template

☐ Use chart specifications from:

File...

OK

Paste

Reset


Cancel

Help

Titles...

Options...

Urmărind cifrele prezentate în grafic, observăm că, din grupul care a obținut rezultate slabe, 16 subiecți nu au beneficiat de repetarea cifrelor de către experimentator și doar 7 au beneficiat de repetare. În schimb, din grupul subiecților care au obținut rezultate bune, 24 de subiecți nu au beneficiat de repetare, iar 32 de subiecți au beneficiat de repetare. Prin urmare, repetarea cifrelor de către experimentator conduce la o mai bună memorare a acestora de către subiecți.



Observație. Atunci când numărul categoriilor de variabile ce trebuie încrucișate crește, recomandăm realizarea graficelor în programul Excel folosind procentele obținute în SPSS, deoarece graficele realizate în SPSS sunt mai puțin estetice.

2.3. Prezentarea grafică a distribuției variabilelor cantitative

2.3.1. Grafice pentru o singură variabilă cantitativă


Există două grafice utilizate frecvent pentru a inspecta forma distribuției unei variabile cantitative (în special pentru verificarea normalității distribuției): histogramele și Q-Q Plots. Pentru obținerea lor există mai multe căi disponibile în SPSS.

Deschidem fișierul *Corelație*. Una dintre modalitățile de obținere a histogramei în SPSS este: *Graphs* → *Histogram*.


The screenshot shows the SPSS Data Editor window titled 'Corelație - SPSS Data Editor'. The menu bar includes File, Edit, View, Data, Transform, Analyze, Graphs, Utilities, and Window. The 'Graphs' menu is open, showing options like Gallery, Interactive, Bar..., Line..., Area..., Pie..., High-Low..., Pareto..., Control..., Boxplot..., Error Bar..., Scatter..., Histogram..., P-P..., Q-Q..., and Sequence... The 'Histogram...' option is highlighted. The data table has columns 'nrsub', 'leadersh', and 'crea'. The first row is selected.

	nrsub	leadersh	crea
1	1	155	
2	2	128	
3	3	163	
4	4	129	
5	5	108	
6	6	112	
7	7	101	
8	8	168	
9	9	152	
10	10	142	
11	11	123	
12	12	122	


Trecem variabila *leadership* în câmpul din dreapta *Variable*, bifăm opțiunea *Display normal curve* pentru a fi afișată și curba frecvențelor și facem clic pe *OK*.




Histograma obținută este prezentată mai jos. Graficul conține pe axa Ox valorile (sub formă de intervale) luate de variabilă *leadership*, iar pe axa Oy numărul de observații (subiecți) corespunzătoare fiecărui interval. Observăm că histograma mai afișează media și abaterea standard calculate pentru variabila *leadership* și numărul de subiecți luat în calcul. Constatăm că distribuția de frecvență a variabilei *leadership* urmează curba unei distribuții normale.




Fiind vorba despre ilustrarea grafică a distribuției unei singure variabile, o altă cale de a obține histogramme în SPSS este: *Analyze* → *Descriptive Statistics* → *Frequencies*.



Trecem variabila *leadership* în câmpul din dreapta *Variable* și apoi activăm butonul *Charts*. Aici avem mai multe opțiuni privind tipul de grafice: sub formă de bare (*Bar charts*), dacă variabila este nominală sau ordinală, sub formă de cerc (*Pie charts*), dacă variabila este nominală și graficul este destinat ilustrării compoziției eșantionului și sub formă de histogramă (*Histograms*), dacă variabila este cantitativă, în acest ultim caz având posibilitatea de a bifa și opțiunea *With normal curve*, pentru curba frecvențelor. Vom alege tipul de grafice prin histograme, iar graficul obținut va fi același cu cel prezentat anterior.



O altă modalitate de verificare a normalității distribuției unei variabile este prin intermediul Q-Q Plot. Calea în SPSS este: *Graphs* → *Q-Q*.



Trecem variabila *leadership* în câmpul din dreapta *Variables*, lăsăm opțiunea *Normal* din câmpul *Test Distribution* selectată pentru a compara distribuția variabilei selectate cu o distribuție normală și facem clic pe *OK*.

Q-Q Plots

Variables: leadership [leadersh]

Test Distribution: Normal

Distribution Parameters:
☒ Estimate from data
 Location: 0
 Scale: 1


Transform:
☐ Natural log transform
☐ Standardize values
☐ Difference:
☐ Seasonally difference
 Current Periodicity: None

Proportion Estimation Formula:
☒ Blom's ☐ Rankit ☐ Tukey's
☐ Van der Waerden's

Rank Assigned to Ties:
☒ Mean ☐ High ☐ Low
☐ Break ties arbitrarily

OK Paste Reset Cancel Help

Graficul obținut este prezentat mai jos. Dacă variabila *leadership* ar fi normal distribuită, atunci graficul ar trebui să prezinte o tendință liniară a datelor deoarece Q-Q Plot compară valorile reale ale variabilei analizate cu cele așteptate în cazul unei distribuții normale. Atunci când șirul de puncte este foarte apropiat de linia trasată variabila tinde să urmeze o distribuție normală.




2.3.2. Grafice pentru o variabilă cantitativă în funcție de nivelele altei/altor variabile calitative


2.3.2.1. Compararea distribuției de frecvențe a unei variabile cantitative în funcție de nivelele altei variabile calitative

Prima situație corespunde prezentării histogramei sau a Q-Q Plot-ului pentru o variabilă cantitativă în cazul fiecăreia dintre categoriile unei alte variabile nominale. Și aici dispunem de mai multe căi în SPSS, una fiind cea prin intermediul procedurii *Split File* și al comenzilor menționate mai sus.

Deschidem fișierul *independent_t_test*. Vom căuta să realizăm histogramele variabilei *leadership* o dată în cazul elevilor beneficiind de un stil parental democratic și, apoi, în cazul celor beneficiind de un stil parental autoritar. Calea pe care o vom alege în SPSS este: *Analyze* → *Descriptive Statistics* → *Explore*.




Trecem variabila cantitativă *motivație intrinsecă* în câmpul *Dependent List*, iar variabila de grupare *stil parental* în câmpul *Factor List*. Din câmpul *Display* din stânga-jos vom selecta opțiunea *Plots*. În continuare activăm butonul *Plots*; aici vom selecta opțiunile *Histogram* pentru afișarea histogramelor și *Normality plots with tests*, dacă dorim prezentarea Q-Q Plot; apoi clic *OK*.



Histogramele obținute sunt prezentate în continuare.


Histogram

For STILPAR= stil democratic




Histogram

For STILPAR= stil autoritar




Dacă dorim să fie afișată și curba frecvențelor, vom face dublu-clic pe grafic în output, iar în noua fereastră *Chart editor* activăm meniul *Chart-Options*, în căsuța de dialog *Histogram Options* bifăm *Normal curve* și clic *OK*, după care închidem fereastra *Chart editor*.




2.3.2.2. Compararea mediilor unei variabile cantitative în funcție de nivelele altei variabile calitative

Atunci când urmărim să comparăm mediile unei variabile cantitative în funcție de categoriile unei alte variabile calitative vom folosi grafice cu bare.

Deschidem fișierul *independent_1_test*. Vom compara grafic mediile obținute de elevi la variabila *motivație intrinsecă* în funcție de variabila *stil parental*. Călea în SPSS este : *Graphs* → *Bar*. În caseta de dialog *Bar Charts* selectăm opțiunile *Simple* și *Summaries for groups of cases*, apoi clic pe butonul *Define*.



Trecem variabila independentă *stil parental* în câmpul *Category Axis*, apoi selectăm opțiunea *Other summary function* și se va activa un nou câmp *Variable* în care vom trece variabila *motivație intrinsecă* și clic *OK*.




Vom obține un grafic prin bare, privind mediile la variabila *motivație intrinsecă* în funcție de variabila *stil parental*. Pentru a obține trecerea mediilor în grafic vom face dublu-clic pe grafic, iar în fereastra Char editor nou deschisă vom face clic pe butonul

Bar Label Style .

Se va deschide o nouă fereastră *Bar Label Styles*, în care vom selecta opțiunea *Framed*, clic pe butonul *Apply All*, clic *Close* și închidem fereastra *Chart Editor*.



Graficul final obținut este prezentat în continuare. Observăm că în cazul elevilor provenind din familii cu un stil parental democratic media la variabila *motivație intrinsecă* este 35,2, iar în cazul celor provenind din familii cu un stil autoritar media este 33,4.




2.3.2.3. Compararea mediilor unei variabile cantitative în funcție de nivelele a două variabile calitative

Uneori ne interesează să prezentăm grafic sub formă de bare compararea mediilor unei variabile cantitative în funcție de nivelele a două variabile calitative. Cazul cel mai frecvent întâlnit este în ANOVA factorială în care avem două variabile independente, iar efectul de interacțiune este semnificativ statistic.


Să presupunem că analizăm modul în care performanța școlară a elevilor depinde de genul subiecților și nivelul ridicat sau scăzut al motivației extrinseci a acestora. Variabila *performanță* este cantitativă (media școlară), iar variabilele *gen* (două categorii : masculin *versus* feminin) și *motivație extrinsecă* (două categorii : nivel scăzut *versus* nivel ridicat) sunt variabile categoriale.

Deschidem fișierul *motivatie_extrinseca*. Calea în SPSS pentru obținerea graficelor cu bare este cea deja cunoscută : *Graphs* → *Bar*.


În caseta de dialog *Bar Charts* selectăm opțiunile *Clustered* și *Summaries for groups of cases*, apoi clic pe butonul *Define*.



Trecem variabila *gen* în câmpul *Category Axis*, variabila *motivatie extrinseca* în câmpul *Define Clusters by*, selectăm opțiunea *Other summary function*, iar în câmpul activat implicit *Variable* trecem variabila *performanta*, apoi clic *OK*.



Graficul obținut este prezentat pe pagina următoare. Trecerea mediilor variabilei performanță în cadrul graficului o vom face prin intermediul ferestrei *Chart editor*, la fel cum am procedat în exemplele prezentate anterior.



Observăm că în cazul băieților, cei cu o motivație extrinsecă scăzută au în medie o performanță de 8,5, iar cei cu motivație extrinsecă ridicată obțin în medie o performanță de 8,2. În schimb, fetele cu o motivație extrinsecă scăzută au în medie o performanță de 9,0, iar cele cu o motivație extrinsecă ridicată obțin în medie o performanță de 9,2.


2.3.3. Grafice pentru două variabile cantitative

2.3.3.1. Grafice pentru ilustrarea liniarității a două variabile cantitative


Uneori, ne interesează să prezentăm grafice pentru două variabile cantitative, în special atunci când verificăm liniaritatea relației dintre variabile. Este cazul corelației, al regresiei liniare sau al analizei de covarianță.

Să presupunem că pe un lot de subiecți am experimentat două metode de predare, una urmărind implicarea ridicată a elevilor în lecție, iar a doua urmărind implicarea scăzută a acestora. Am măsurat performanța elevilor la sfârșitul lecției și, anterior, coeficientul de inteligență al acestora. Ne interesează în prima fază să verificăm dacă există o relație liniară între IQ și performanță.


Deschidem fișierul *ANCOVA*. Calea de obținere a graficului în SPSS este : *Graphs* → *Scatter*.




În caseta de dialog deschisă selectăm opțiunea *Simple* ; apoi clic pe *Define*.




Trecem variabila dependentă *performanta* în câmpul *Y Axis*, iar variabila independentă *coeficientul de inteligenta* în câmpul *X Axis*, apoi apăsăm butonul *OK*.




Graficul obținut este redat mai jos și prezintă într-un spațiu bidimensional valorile luate de cele două variabile. Pe axa Ox sunt prezentate valorile pe care le ia variabila *coeficientul de inteligenta*, iar pe axa OY sunt prezentate valorile luate de variabila *performanta*.



Pentru o estimare mai bună a liniarității dintre cele două variabile putem opta ca în grafic să apară o linie care estimează liniaritatea relației. Facem dublu-clic pe grafic, iar în fereastra *Chart editor* alegem meniul *Chart* → *Options*. În fereastră deschisă, *Scatterplot Options*, bifăm opțiunea *Total* din câmpul *Fit Line*, clic *OK* și închidem fereastra *Chart editor*.




Graficul obținut va arăta astfel :




Observăm că norul de puncte urmează direcția liniei trasate. Cu cât norul de puncte este mai apropiat de linie, cu atât relația liniară dintre variabile este mai puternică.

Uneori este interesant de identificat și ulterior de eliminat (urmând a fi discutat separat) un caz/subiect care distorsionează liniaritatea relației dintre variabile. Deschidem

baza de date *liniaritate_1*. Baza de date este similară cu cea discutată anterior, doar că, după cum vom vedea, conține un caz care distorsionează liniaritatea variabilelor *QI* și *performanta*. Urmăm aceeași cale ca mai sus până ajungem în fereastra *Simple Scatterplot*, unde vom considera în plus variabila *nrsb* (numărul de ordine al subiecților), în câmpul *Label Cases by*, activăm butonul *Options*, iar aici bifăm opțiunea *Display chart with case labels*, clic *Continue* și *OK*.



În noul grafic obținut, pentru fiecare dintre valorile celor două variabile apare afișat și numărul de ordine al subiectului care ia o anumită valoare. Observăm că există un caz extrem în datele noastre care afectează liniaritatea celor două variabile, respectiv subiectul 33 care are o valoare foarte mică la variabila *QI* și o valoare foarte mare la variabila *performanta*.




Cunoscând numărul de ordine al acestui subiect va fi ușor de identificat în baza de date și de eliminat din analiză, urmând ca ulterior să îl discutăm separat. Este foarte posibil ca acest subiect cu un *QI* foarte mic care a luat o notă foarte mare la test să fi copiat, de exemplu.


2.3.3.2. Grafice pentru ilustrarea liniarității a două variabile cantitative, diferențiat, în funcție de o a treia variabilă calitativă

În condițiile studiului menționat anterior, presupunem că dorim să verificăm liniaritatea relației dintre *QI* și *performanta* atât pentru grupul de elevi cu o implicare scăzută, cât și pentru cei cu o implicare ridicată.


Deschideți fișierul *ANCOVA*. Urmăm aceeași cale ca în exemplele anterioare (*Graphs* → *Scatter* etc.) până ajungem în fereastra *Simple Scatterplot*, unde vom trece în plus variabila *gradul de implicare* în câmpul *Set Markers by*; clic *OK*.



Dacă dorim să trasăm liniile ce estimează liniaritatea relației dintre variabile pentru fiecare dintre cele două grupuri vom face dublu-clic pe graficul obținut, apoi în fereastra deschisă *Chart editor* alegem meniul *Chart* → *Options*, iar acolo în câmpul *Fit Line*, bifăm opțiunea *Subgroups*; clic *OK* și închidem fereastra *Chart editor*.



Graficul obținut în final este prezentat mai jos. Observăm că în cazul subiecților cu implicare ridicată norul de puncte este mai apropiat de linia corespunzătoare comparativ cu grupul subiecților având o implicare scăzută; prin urmare, liniaritatea relației este mai puternică în primul caz decât în cel de-al doilea. De asemenea, observăm că linia corespunzătoare grupului cu implicare ridicată este deasupra liniei corespunzătoare grupului cu implicare scăzută, ceea ce înseamnă că performanțele obținute sunt mai mari în situația de implicare ridicată comparativ cu situația de implicare scăzută.



Capitolul 3. Analiza răspunsurilor multiple

3.1. Prezentare generală

Analiza răspunsurilor multiple permite cercetătorului să studieze itemii cu mai multe variante de răspuns. De exemplu, putem solicita unor subiecți cadre didactice să enumere avantajele implicării în proiecte educaționale. Sau am putea, de exemplu, să rugăm un grup de subiecți studenți să bifeze tipurile de activități în care se angajează în mod frecvent pe internet dintr-o listă oferită. Nu în ultimul rând, ne-ar putea interesa să aflăm care sunt emisiunile culturale urmărite de elevi în ultimele două luni, fie rugându-i să le enumere, fie rugându-i să bifeze dintr-o listă prestabilită.

O modalitate de a obține statistici descriptive privind răspunsurile subiecților la acești itemi ar fi să realizăm tabele de frecvență așa cum am văzut într-un capitol anterior, separat pentru fiecare dintre răspunsurile primite la itemi. Raportându-ne la ultimul exemplu, analiza de frecvențe obișnuită are dezavantajul că ne va oferi procentul de alegeri obținute pentru emisiunea culturală „X” din totalul subiecților investigați, adică luându-i în calcul și pe subiecții care nu urmăresc emisiuni culturale și care, prin urmare, nu au încercuit nici o emisiune din lista oferită.

Analiza răspunsurilor multiple, în schimb, va afișa *procentul de alegeri obținute pentru emisiunea „X” din totalul subiecților care urmăresc emisiuni culturale* (și prin urmare au încercuit cel puțin o emisiune din lista oferită).

Există două modalități de a analiza răspunsurile multiple. Prima este aceea în care cercetătorul va crea câte o variabilă dihotomică pentru fiecare răspuns posibil, de exemplu: 1 pentru *da* și 2 pentru *nu*; aceasta este *metoda răspunsurilor multiple dihotomice*. A doua modalitate de analiză presupune alegerea dintr-o listă de avantaje ale internetului în activitatea didactică, de exemplu, a *doar* trei avantaje. În acest caz, vom codifica toate avantajele oferite spre alegere subiectului de la 1 la 10 (în cazul în care oferim o listă de zece avantaje), iar ulterior vom crea trei noi variabile denumite avantaj1, avantaj2 și avantaj3; aceasta este *metoda răspunsurilor multiple*.

3.2. Analiza răspunsurilor multiple dihotomice


Să presupunem că într-o cercetare vizând activitățile pe care tinerii le desfășoară pe internet subiecții sunt rugați să răspundă la următoarea întrebare:

*În care dintre următoarele tipuri de activități vă angajați în mod frecvent pe internet ?
(Puteți alege una sau mai multe dintre variantele corespunzătoare.)*

	1. Da	2. Nu
1. utilizarea e-mailului	—	—
2. căutarea de informații uzuale	—	—
3. citirea/vizualizarea știrilor	—	—
4. accesarea jocurilor	—	—
5. mesagerie instant	—	—
6. ascultare și descărcare de mp3-uri și filme	—	—
7. descărcarea de softuri, documente	—	—
8. ascultarea unor posturi de radio sau vizionarea de emisiuni TV	—	—

3.2.1. Aplicarea analizei răspunsurilor multiple dihotomice

Deschidem fișierul *internet*. Baza de date va arăta astfel :



	Name	Type	Width	Deci	Label	Values
1	item1	Numeric	8	0	e-mail	{1, da}...
2	item2	Numeric	8	0	informatii uzuale	{1, da}...
3	item3	Numeric	8	0	stiri	{1, da}...
4	item4	Numeric	8	0	jocuri	{1, da}...
5	item5	Numeric	8	0	mesagerie instant	{1, da}...
6	item6	Numeric	8	0	Mp3-uri si filme	{1, da}...
7	item7	Numeric	8	0	documente, soft-uri	{1, da}...
8	item8	Numeric	8	0	radio, tv	{1, da}...

Calea de analiză a răspunsurilor multiple dihotomice în SPSS este: *Analyze → Multiple Response → Define Sets*.

internet - SPSS Data Editor

File Edit View Data Transform **Analyze** Graphs Utilities Window Help

Reports
Descriptive Statistics
Compare Means
General Linear Model
Correlate
Regression
Loglinear
Classify
Data Reduction
Scale
Nonparametric Tests
Survival
Multiple Response

Define Sets...

Frequencies...
Crosstabs...

	item1	item2		item5
1 : item1	1			
1	1			1
2	1			1
3	1			2
4	2			2
5	2			1
6	1			1
7	2			2
8	2			1
9	2	1	2	
10	1	1	2	

Trecem itemii de la item1 la item8 în câmpul *Variables in set*.

Define Multiple Response Sets

Set Definition

gen

Variables in Set:

- e-mail [item1]
- informatii uzuale [ite]
- stiri [item3]
- jocuri [item4]
- mesagerie instant [i]

Variables Are Coded As

☒ Dichotomies Counted value: 1

☐ Categories Range: through

Name: internet


Label: activitati internet

Add
Change
Remove


Mult Response Sets:

Close
Help

Ne asigurăm că este selectată opțiunea *Dichotomies Counted value*, iar în câmpul activat trecem valoarea 1. În câmpul *Name* trecem numele acestui set de răspunsuri multiple – *internet* –, iar mai jos, în câmpul *Label*, trecem o descriere a setului, în cazul de față *activitati internet*. Apoi, facem clic pe butonul *Add* din dreapta pentru a trece acest set de răspunsuri multiple în câmpul din dreapta-jos – *Mult Response sets*; clic *Close*.



În acest moment am definit setul de răspunsuri multiple *internet*. În continuare, pentru analiza răspunsurilor multiple, vom urma în SPSS calea: *Analyze* → *Multiple Response* → *Frequencies*.



Trecem setul de răspunsuri multiple *internet* în câmpul din dreapta *Table(s) for* și apăsăm butonul **OK**.

Multiple Response Frequencies

Mult Response Sets:

Table(s) for:

☐ activitati internet [\$inte]

OK

Paste

Reset

Cancel

Help

Missing Values

☐ Exclude cases listwise within dichotomies

☐ Exclude cases listwise within categories

3.2.2. Interpretarea outputului

Rezultatele obținute în output sunt prezentate mai jos.

Group \$INTERNET activitati internet
(Value tabulated = 1)

Dichotomy label	Name	Count	Pct of Responses	Pct of Cases
e-mail	ITEM1	41	15,0	70,7
informatii uzuale	ITEM2	52	19,0	89,7
stiri	ITEM3	19	7,0	32,8
jocuri	ITEM4	19	7,0	32,8
mesagerie instant	ITEM5	47	17,2	81,0
Mp3-uri si filme	ITEM6	53	19,4	91,4
documente, soft-uri	ITEM7	27	9,9	46,6
radio, tv	ITEM8	15	5,5	25,9
Total responses		273	100,0	470,7

0 missing cases; 58 valid cases

Coloana Count conține numărul de subiecți care au răspuns cu Da la fiecare dintre cei opt itemi. În partea de jos a tabelului observăm că au fost luate în considerare 58 de

cazuri valide, ceea ce înseamnă că fiecare dintre subiecții investigați au răspuns cu *da* la cel puțin unul dintre itemi.

Dacă, de exemplu, într-un studiu vizând cititorii de ziare ieșene am fi identificat existența a șapte astfel de publicații, iar un total de 100 de subiecți ar fi fost rugați să bifeze dacă citesc sau nu fiecare ziar, ar fi putut exista un număr de 15 subiecți care au marcat *nu* la toate cele șapte ziare. Așadar, acești 15 subiecți ar fi din categoria celor care *nu citeșc ziare ieșene*, iar în output, în partea din stânga-jos ar fi fost afișate 15 cazuri lipsă și 85 de cazuri valide. Analiza răspunsurilor multiple calculează în acest caz procentul de cititori ai fiecărui ziar ieșean din totalul cititorilor de ziare ieșene, respectiv din totalul cazurilor valide!

Revenind la exemplul nostru, procentele din coloana *Pct of Responses* sunt calculate prin raportarea numărului de subiecți care au răspuns *da* la fiecare dintre cei opt itemi (din coloana *Count*) la numărul total de răspunsuri afirmative pe care subiecții le-au generat (273 în cazul de față). Astfel, pentru utilizarea e-mailului, procentul de 15%

reprezintă 41 din 273 și este calculat astfel : $\frac{41 \times 100}{273} = 15$.

În coloana *Pct of Cases* conține procentele de subiecți care au răspuns *da* la fiecare dintre cei opt itemi din totalul cazurilor valide, respectiv 58. Astfel, din totalul subiecților care utilizează aceste aplicații pe internet (N = 58 subiecți), 70,7% folosesc e-mail-ul, 89,7% caută informații uzuale, 32,8% urmăresc știrile etc. Modalitatea de calcul a

acestor procente este, de exemplu pentru itemul_1 (e-mail), $\frac{41 \times 100}{58} = 70,7$.

3.3. Analiza răspunsurilor multiple

Să presupunem acum că în cercetarea despre care am vorbit anterior îi rugăm pe subiecți să aleagă și încercuiască trei dintre activitățile pe care le desfășoară cel mai frecvent pe internet din cele opt prezentate.

Cercetătorul va codifica fiecare dintre cele opt activități astfel :

- 1 = utilizarea e-mailului
- 2 = căutarea de informații uzuale
- 3 = citirea/vizualizarea știrilor
- 4 = accesarea jocurilor
- 5 = mesagerie instant
- 6 = ascultare și descărcare de Mp3-uri și filme
- 7 = descărcarea de softuri, documente
- 8 = ascultarea unor posturi de radio sau vizionarea de emisiuni tv

Deoarece subiecții trebuie să aleagă trei activități, vom defini în baza de date alte trei noi variabile : aleg_1, aleg_2 și aleg_3, iar în cadrul fiecăreia vom defini valorile celor opt activități, precum am arătat mai sus.

3.3.1. Aplicarea analizei răspunsurilor multiple

Deschidem baza de date *internet_2*. Baza de date va arăta astfel:

Internet_2 - SPSS Data Editor

File Edit View Data Transform Analyze Graphs Utilities Windows Help

	Name	Type	Width	Deci	Label	Values	Missing	Columns
1	item1	Numeric	8	0	e-mail			
2	item2	Numeric	8	0	inform			
3	item3	Numeric	8	0	stiri			
4	item4	Numeric	8	0	jocuri			
5	item5	Numeric	8	0	mesag			
6	item6	Numeric	8	0	Mp3-u			
7	item7	Numeric	8	0	docum			
8	item8	Numeric	8	0	radio,			
9	gen	Numeric	8	0				
10	aleg_1	Numeric	8	0	prima			
11	aleg_2	Numeric	8	0	a doua alegere	{1, mail}...	None	8
12	aleg_3	Numeric	8	0	a treia alegere	{1, mail}...	None	8

Value Labels

Value Labels:

Value:

Value Label:

Add

Changes

Remove

6 = "Mp3-uri, filme"
7 = "soft, documente"
8 = "radio, tv"

OK

Cancel

Help

Calea de analiză a răspunsurilor multiple dihotomice este: *Analyze* → *Multiple Response* → *Define Sets*. Trecem variabilele *aleg_1*, *aleg_2* și *aleg_3* în câmpul *Variable in Set*, apoi în câmpul *Variables Are Coded As* selectăm opțiunea *Categories* și trecem rangurile pe care le pot lua variabilele, de la 1 la 8, apoi scriem numele setului de răspunsuri multiple creat *alegeri* și denumim setul *activitati frecvente*.

Define Multiple Response Sets

Set Definition

Variables in Set:

Variables Are Coded As:

Dichotomies Counted value:

Categories Range: 1 through 8

Name: alegeri

Label: activitati frecvente

Add

Change

Remove

Mult Response Sets:

Close

Help

Mai departe trecem setul de răspunsuri multiple cu un clic pe butonul *Add* în câmpul *Mult Response Sets* și clic *Close*.

Define Multiple Response Sets

Set Definition

Variables in Set:

documente, soft-uri
radio, tv [item8]
gen
prima alegere [aleg]
a doua alegere [ale]
a treia alegere [ale]

Variables Are Coded As

☒ Dichotomies Counted value:
☐ Categories Range: through

Name:
Label:

Mult Response Sets:
\$alegeri

Add
Change
Remove

Close
Help

În continuare, pentru analiza răspunsurilor multiple la acest set vom urma în SPSS calea: *Analyze* → *Multiple Response* → *Frequencies*. Trecem variabila-set *activități frecvente* în câmpul din dreapta *Table(s) for* și clic *OK*.

Multiple Response Frequencies

Mult Response Sets:

Table(s) for:
☒ activitati frecvente [\$al]

Missing Values

☐ Exclude cases listwise within dichotomies
☐ Exclude cases listwise within categories

OK
Paste
Reset
Cancel
Help

3.3.2. Interpretarea outputului

Rezultatele obținute în output sunt prezentate mai jos.

Group \$ALEGERI activitati frecvente				
Category label	Code	Count	Pct of Responses	Pct of Cases
mail	1	33	19,0	56,9
informatii	2	42	24,1	72,4
stiri	3	4	2,3	6,9
jocuri	4	5	2,9	8,6
mesagerie	5	35	20,1	60,3
Mp3-uri, filme	6	32	18,4	55,2
soft, documente	7	23	13,2	39,7
Total responses		174	100,0	300,0
0 missing cases; 58 valid cases				

În coloana *Code* sunt prezentate codurile pentru cele șapte activități alese. Observăm că, deși noi prezentaserăm opt activități din care trebuiau alese trei cele mai frecvente, a opta nu a fost aleasă niciodată în primele trei și, prin urmare, SPSS a făcut analiza doar pentru cele șapte activități care se regăseau în cele trei alegeri ale subiecților.

Coloana *Count* conține numărul subiecților care au nominalizat fiecare dintre cele opt activități. În partea de jos a tabelului observăm că au fost luate în considerare 58 de cazuri valide. Constatăm că dintre cei 58 de subiecți, 33 au nominalizat activitatea *utilizarea e-mailului*, 42 au nominalizat *căutarea de informații uzuale*, 4 au nominalizat *citirea știrilor* etc. Per total s-au înregistrat 174 de nominalizări.

Procentele prezentate în coloana *Pct of Responses* reprezintă procentul de subiecți care au nominalizat fiecare dintre cele opt activități din totalul numărului de nominalizări generate (174). Astfel, pentru *mail*, procentul de 19% reprezintă 33 din 174 și este

$$\text{calculat astfel: } \frac{33 \times 100}{174} = 19.$$

Coloana *Pct of Cases* prezintă procentele de subiecți care au nominalizat fiecare dintre cele opt activități din totalul cazurilor valide, respectiv 58. Astfel, cei 33 de subiecți care au nominalizat *utilizarea e-mailului* în alegeri reprezintă 56,9% din totalul de cazuri valide (58). Modalitatea de calcul a procentului pentru cei care au ales

$$\text{utilizarea e-mailului este: } \frac{33 \times 100}{58} = 56,9.$$

3.4. Analiza răspunsurilor multiple în funcție de o variabilă nominală

Uneori, cercetătorul poate alege să analizeze răspunsurile multiple diferențiat în funcție de o variabilă nominală, analizând răspunsurile multiple ale subiecților diferențiat după variabila *gen*, de exemplu.


3.4.1. Analiza răspunsurilor diferențiat, după nivelele unei variabile nominale

Vom analiza răspunsurile multiple dihotomice în funcție de variabila *gen*. Deschidem baza de date *internet*. Călea de analiză a răspunsurilor multiple în SPSS este: *Analyze* → *Multiple Response* → *Define Sets*. Trecem itemii de la item1 la item8 în câmpul *Variable in set*. Ne asigurăm că este selectată opțiunea *Dichotomies Counted value*, iar în câmpul activat trecem valoarea 1. Apoi, în câmpul *Name* trecem numele acestui set de răspunsuri multiple *internet*, iar mai jos în câmpul *Label* trecem o descriere a setului, în cazul de față *activități internet*. Apoi, facem clic pe butonul *Add* din dreapta pentru a trece acest set de răspunsuri multiple în câmpul din dreapta-jos *Multiple Response sets*, apoi clic *Close*. În acest moment am definit setul de răspunsuri multiple *internet*. În continuare, pentru analiza răspunsurilor multiple la acest set vom urma în SPSS călea: *Analyze* → *Multiple Response* → *Crosstabs*.


The screenshot shows the SPSS Data Editor window for the 'internet' dataset. The data table has columns 'item1', 'item2', and 'item5'. The 'Analyze' menu is open, showing the 'Multiple Response' option selected. The 'Define Sets...' dialog box is also visible, showing the 'Variable in set' list with items 1 through 8, and the 'Name' field set to 'internet'.

	item1	item2	item5
1	1		1
2	1		1
3	1		2
4	2		2
5	2		1
6	1		1
7	2		2
8	2		1
9	2	1	2
10	1	1	2

Trecem setul de răspunsuri multiple *internet* în câmpul *Row(s)*, variabila *gen* în câmpul *Column(s)*; clic pe butonul *Define Rangers*, pentru a defini nivelele variabilei *gen*, trecem valorile „1” în câmpul *Minimum* și „2” în câmpul *Maximum* și clic *Continue*.



Activăm butonul *Options* și aici, în câmpul *Cell Percentages*, selectăm opțiunile *Row*, *Column* și *Total*, clic *Continue* și clic *OK*.



3.4.2. Interpretarea outputului

Rezultatele obținute în output sunt prezentate mai jos.

* * * C R O S S T A B U L A T I O N * * *

ȘINTERNE (tabulating 1) activitati internet by GEN

		GEN		
		Count	masculin	feminin
		Row pct		
		Col pct		
		Tab pct	1	2
ȘINTERNE				Row Total
e-mail	ITEM1		16	25
			39,0	61,0
			66,7	73,5
			27,6	43,1
informatii uzuale	ITEM2		21	31
			40,4	59,6
			87,5	91,2
			36,2	53,4
stiri	ITEM3		9	10
			47,4	52,6
			37,5	29,4
			15,5	17,2
jocuri	ITEM4		14	5
			73,7	26,3
			58,3	14,7
			24,1	8,6
mesagerie instant	ITEM5		19	28
			40,4	59,6
			79,2	82,4
			32,8	48,3
Mp3-uri si filme	ITEM6		21	32
			39,6	60,4
			87,5	94,1
			36,2	55,2

	ITEM7	16	11	27
documente, soft-uri		59,3	40,7	46,6
		66,7	32,4	
		27,6	19,0	
	ITEM8	5	10	15
radio, tv		33,3	66,7	25,9
		20,8	29,4	
		8,6	17,2	
	Column	24	34	58
	Total	41,4	58,6	100,0
Percents and totals based on respondents				
58 valid cases; 0 missing cases				

În cadrul acestui tabel afișat în output, pentru fiecare dintre itemi pe linie sunt prezentate informațiile astfel: prima linie *Count*, a doua linie *Row pct*, a treia linie *Col pct*, iar a patra linie *Tab pct*. Vom discuta acest tabel doar pentru variabila *e-mail*.

- Pe linia *Count* sunt prezentate frecvențele, numărul de băieți și numărul de fete care folosesc *e-mailul* precum și per total. Observăm că folosirea *e-mailului* e bifată de 16 băieți, 25 de fete, iar per total numărul de subiecți care folosesc această activitate pe internet este de 41.
- Linia *Row pct* prezintă procentul de băieți care folosesc *e-mailul* din totalul subiecților care folosesc *e-mailul* (41), și procentul de fete care folosesc această activitate din total. Astfel, dintre cei 41 de subiecți care au declarat că se angajează în acest tip de activitate pe internet, 39% sunt băieți, iar 61% sunt fete.
- Linia *Col pct* afișează procentele de băieți și fete care folosesc *e-mailul* din totalul băieților și fetelor care folosesc cel puțin un tip de activitate din cele opt pe internet. Astfel, din totalul de 58 de subiecți care folosesc astfel de activități pe internet, 24 sunt băieți, iar 34 sunt fete (vezi la finalul tabelului, linia *Column*). Cei 16 băieți care folosesc *e-mailul* reprezintă 66,7% din totalul de 24 de băieți care se angajează în activitățile enumerate pe internet. De asemenea, cele 25 de fete care folosesc *e-mailul* reprezintă 73,5% din totalul de fete care se angajează în cel puțin una dintre cele opt activități enumerate pe internet.
- Linia *Tab pct* prezintă procentele de băieți și fete care folosesc *e-mailul* din totalul cazurilor valide (58). Astfel, cei 16 băieți care folosesc *e-mailul* reprezintă 27,6% din totalul de 58 de subiecți, iar cele 25 de fete care folosesc *e-mailul* reprezintă 43,1% din totalul subiecților care se angajează în cel puțin un tip de activitate (dintre cele opt enumerate) pe internet.

Capitolul 4. Noțiuni de bază privind testarea ipotezelor statistice

4.1. Ipoteze unidirecționale și ipoteze bidirecționale

Ipotezele de cercetare lansate pot fi de două tipuri: 1) ipoteze unidirecționale, unilaterale (*one-tailed*) și 2) ipoteze bidirecționale, bilaterale (*two-tailed*).

O *ipoteză unidirecțională* specifică exact direcția relației dintre două variabile. Să luăm câteva exemple: 1) Există o corelație pozitivă între timpul alocat studiului și performanța școlară; 2) Femeile au o inteligență emoțională mai dezvoltată comparativ cu bărbații etc.

Ipotezele bidirecționale, în schimb, nu specifică natura relației dintre două variabile. Exemple: 1) Există o corelație între inteligența emoțională și performanța școlară; 2) Există diferențe semnificative între femei și bărbați în ceea ce privește manifestarea emoțiilor etc.

Elementul statistic important în această diferențiere între ipotezele unidirecționale și cele bidirecționale este că în SPSS *pragul de semnificație p* adiacent rezultatelor la testele statistice *este un prag de semnificație bidirecțional ($two-tailed$)* specific ipotezelor bidirecționale. Astfel, atunci când analizăm ipoteze bidirecționale, ne vom raporta la pragul de semnificație p afișat de SPSS, iar când analizăm ipoteze unidirecționale vom înjumătăți pragul de semnificație p afișat (*two-tailed*) și ne vom raporta la această valoare.

De exemplu, dacă SPSS prezintă un rezultat de genul $t(101) = 1,83, p = 0,07$, acest rezultat este relevant pentru cazul în care ipoteza noastră ar fi fost bidirecțională. Dacă ipoteza noastră este unidirecțională, iar rezultatul testului t confirmă direcția așteptată, atunci rezultatul relevant va fi următorul: $t(101) = 1,828, p = 0,035$ (*one-tailed*). Atenție! Înjumătățim numai pragul de semnificație p , nu și rezultatul la testul statistic (fie acesta t , F , r etc.) și precizăm în paranteză *one-tailed*.

4.2. Erorile de tipul I și cele de tipul II în testarea ipotezelor

În testarea ipotezelor ne referim la două tipuri de ipoteze: ipoteza nulă H_0 și ipoteza de cercetare H_1 . Ipoteza nulă presupune că nu există nici o relație între cele două variabile, sau că nu există diferențe semnificative între două grupuri etc., în vreme ce ipoteza de cercetare presupune că există o corelație între două variabile sau există diferențe

semnificative între două grupuri etc. Scopul urmărit într-un studiu este respingerea H_0 și implicit acceptarea H_1 .

Eroarea de tipul I apare atunci când respingem H_0 , deși ea de fapt nu trebuia respinsă. *Eroarea de tipul II* apare atunci când nu respingem H_0 , deși ea trebuia respinsă. Între cele două tipuri de erori există o relație de reciprocitate: crescând șansele de a comite eroarea de tipul I scad șansele de a comite eroarea de tipul II și invers, scăzând șansele de a comite eroarea de tipul I cresc șansele de a comite eroarea de tipul II. Concret, comitem eroarea de tipul I atunci când considerăm că studiul nostru pune în evidență un efect, deși acesta nu există în realitate; comitem eroarea de tipul II atunci când studiul nostru nu evidențiază un efect analizat, iar acesta există în realitate.

Exemplu. Studiem dacă există o corelație pozitivă între numărul de ore alocate studiului săptămânal de către elevi și performanța școlară a acestora și găsim un coeficient de corelație $r(18) = 0,36$ și un prag de semnificație $p = 0,119$ ($p > 0,05$), fapt ce arată că există o probabilitate de 12% ca relația dintre cele două variabile observată pe eșantion să apară din întâmplare. Am putea concluziona că nu există o corelație semnificativă între cele două variabile, ceea ce este incorect, deoarece practica ne arată că, cu cât alocăm mai mult timp studiului, cu atât performanța școlară va crește. Am făcut în acest caz o eroare de tipul II, adică am respins H_1 , când aceasta era de fapt adevărată. Dacă ne aflăm într-un asemenea caz, ar trebui să ne întrebăm de ce, dacă există o corelație sau o diferență reală în populație, noi nu am reușit să o detectăm în studiul nostru. Răspunsurile pot fi multiple:

1. erori în selectarea subiecților pentru cercetare – selecția a *căzut* pe un oarecare bias (am selectat subiecți având anumite caracteristici distincte, fiind oarecum diferiți de populația generală – de exemplu, subiecți cu un $QI < 60$)
2. *designul metodologic și statistic este unul slab*: instrumentele de măsurare au o fidelitate și o validitate scăzute; variabilele nu sunt normal distribuite etc.
3. *lotul de subiecți este redus* etc.

Asemenea factori reduc puterea cercetării noastre în detectarea diferențelor sau a corelațiilor reale în populație, atunci când acestea există.

4.3. Testarea normalității unei distribuții

Toate metodele statistice parametrice (testele t , corelația, ANOVA, regresia liniară etc.) au la bază condiția de normalitate a distribuției variabilelor cantitative: distribuția scorurilor acestor variabile nu diferă semnificativ de o distribuție normală.

Atunci când condiția de normalitate a distribuției nu este îndeplinită, se recomandă:

- 1) fie aplicarea testelor neparametrice; 2) fie transformarea variabilei respective prin diferite operații precum logaritmarea, extragerea radicalului etc.; 3) fie categorizarea variabilei respective (împărțirea scorurilor pe trei nivele, de exemplu).

Există două demersuri în verificarea normalității unei distribuții: unul *grafic* și unul *statistic*. În cazul demersului grafic, cea mai frecventă tehnică este reprezentarea datelor sub forma *histogramei*. În cazul demersului statistic, cel mai frecvent folosit test este *testul Kolmogorov-Smirnov pentru un eșantion*.


Aplicație. Deschidem fișierul *Comportament_prosocial*. Vom verifica normalitatea distribuției variabilei *comportament_prosocial*.

4.3.1. Demersul grafic


Vom reprezenta grafic scorurile variabilei sub forma unei histograme și apoi vom compara distribuția scorurilor cu distribuția normală. Calea în SPSS este : *Graphs* → *Histogram*.



Trecem variabila *comportament_prosocial* în câmpul *Variable*, bifăm opțiunea *Display normal curve* și clic *OK*.




Rezultatul apare sub forma unui grafic precum cel de mai jos. Dezavantajul acestui demers este subiectivismul în a aprecia dacă o distribuție este conformă cu cea normală sau nu. De aceea, avem nevoie de un test statistic, obiectiv, pentru a decide dacă o distribuție diferă semnificativ de una normală sau nu.




4.3.2. Demersul statistic

4.3.2.1. Testul Kolmogorov-Smirnov pentru un eșantion

Acest test compară distribuția scorurilor variabilei pe eșantion cu o distribuție normală având aceleași medie și deviație standard. Dacă rezultatul la acest test este nesemnificativ statistic ($p > 0,05$), atunci distribuția variabilei pe eșantion nu diferă semnificativ de o distribuție normală și, prin urmare, variabila este normal distribuită. Calea în SPSS este: *Analyze* → *Nonparametric tests* → *1-Sample K-S*.



Trecem variabila *comportament prosocial* în câmpul *Test Variable List*, bifăm opțiunea *Normal* și clic *OK*.



Rezultatele la testul Kolmogorov-Smirnov sunt prezentate în tabelul *One-Sample Kolmogorov-Smirnov Test*. Observăm că rezultatul la testul K-S este nesemnificativ statistic, $z = 0,757$, $p = 0,616$, prin urmare distribuția variabilei *comportament prosocial* nu diferă semnificativ de o distribuție normală. Inspectând și repartizarea scorurilor sub forma unei histogramme constatăm că distribuția scorurilor urmează o distribuție normală.

One-Sample Kolmogorov-Smirnov Test

		comportament prosocial
N		200
Normal Parameters ^{a,b}	Mean	54,37
	Std. Deviation	7,43
Most Extreme Differences	Absolute	,054
	Positive	,040
	Negative	-,054
Kolmogorov-Smirnov Z		,757
Asymp. Sig. (2-tailed)		,616

a. Test distribution is Normal.


b. Calculated from data.

O altă cale de aplicare a acestui test este: *Analyze* → *Descriptive Statistics* → *Explore*; o vom detalia în continuare.


4.3.2.2. Testul Shapiro-Wilk

Și acest test verifică normalitatea unei distribuții, fiind asemănător testului Kolmogorov-Smirnov. În general, testul Shapiro-Wilk este mai puternic decât testul Kolmogorov-Smirnov (Field, 2000; Iacobucci, 2001).

Calea în SPSS este: *Analyze* → *Descriptive Statistics* → *Explore*.



Trecem variabila *comportament prosocial* în câmpul *Dependent List*, apoi activăm butonul *Plots*, iar aici selectăm opțiunea *Normality plots with tests*, clic *Continue* și clic *OK*.



Rezultatele relevante se regăesc în tabelele *Descriptives* și *Tests of Normality* de mai jos. Din tabelul *Descriptives* ne vor interesa coeficienții Skewness și Kurtosis pe care îi vom discuta mai jos.

Descriptives

			Statistic	Std. Error
comportament prosocial	Mean		54,37	,53
	95% Confidence Interval for Mean	Lower Bound	53,33	
		Upper Bound	55,40	
	5% Trimmed Mean		54,37	
	Median		55,00	
	Variance		55,248	
	Std. Deviation		7,43	
	Minimum		32	
	Maximum		75	
	Range		43	
	Interquartile Range		10,75	
	Skewness		-,054	,172
	Kurtosis		-,133	,342

În tabelul *Tests of Normality* sunt prezentate rezultatele la testele Shapiro-Wilk (S-W) și Kolmogorov-Smirnov (K-S) ; acestea trebuie să fie *ne semnificative statistic* ($p > 0,05$) pentru ca variabila să fie normal distribuită în populație. Observăm că rezultatul la testul K-S este $K-S(200) = 0,054$, $p = 0,200$, iar rezultatul la testul S-W este $S-W(200) = 0,995$, $p = 0,914$. Cum rezultatele la ambele teste sunt *ne semnificative statistic*, rezultă că variabila este normal distribuită.

Tests of Normality

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
comportament prosocial	,054	200	,200*	,995	200	,814

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

4.3.2.3. Coeficienții de asimetrie (skewness) și de boltire (kurtosis)

Într-o distribuție perfect normală acești coeficienți sunt zero.

Coeficientul de asimetrie exprimă gradul de deplasare la stânga sau la dreapta a distribuției unei variabilei comparativ cu o distribuție normală; valori negative ale acestuia indică o asimetrie (deplasare) la stânga, iar valori pozitive indică o asimetrie la dreapta.

Coeficientul de boltire exprimă gradul de grupare a observațiilor în jurul valorii centrale. Când coeficientul este mai mare decât zero, curba este mai boltită (înaltă), iar când este mai mic decât zero curba este mai puțin boltită comparativ cu cea a unei distribuții normale.

Cum decidem dacă o variabilă urmează o distribuție normală? Există și aici mai multe opinii. Unii cercetători (Field, 2000; Leech, Barrett și Morgan, 2005) recomandă transformarea celor doi coeficienți în note *z*, astfel:

$$z_{\text{skewness}} = \frac{S - 0}{SE_{\text{skewness}}} \quad z_{\text{kurtosis}} = \frac{K - 0}{SE_{\text{kurtosis}}}$$

Dacă una dintre notele *z* astfel obținute în valoare absolută este mai mare decât 2,0 sau 2,5 (pentru cazul unor eșantioane de volum redus), atunci distribuția diferă semnificativ de o distribuție normală. Problema în acest caz este că eroarea standard a asimetriei (SE) depinde de mărimea eșantionului, iar în cazul unor eșantioane foarte mari de cele mai multe ori am putea trage concluzia (greșită) că variabilele nu sunt normal distribuite. În

cazul datelor noastre, $z_{\text{skewness}} = \frac{0,054}{0,172} = 0,313$ și $z_{\text{kurtosis}} = \frac{0,133}{0,342} = 0,623$; prin urmare, variabila este normal distribuită.

După alți autori, distribuția unei variabile diferă de o distribuție normală dacă coeficientul skewness în valoare absolută este mai mare decât 1 (Morgan, Leech, Gloeckner și Barrett, 2004).

Notă: unii cercetători consideră că majoritatea tehnicilor parametrice (teste *t*, tehnicile ANOVA etc.) sunt destul de robuste, putând fi aplicate și în cazul unor variabile care nu sunt normal distribuite (devierea față de o distribuție normală trebuie să nu fie severă), aceasta doar în cazul unor ipoteze bidirecționale (*two-tailed*). Dacă însă încălcarea acestei condiții se combină cu încălcarea altor condiții specifice tehnicilor respective (de exemplu, omogenitatea varianțelor în cazul ANOVA), atunci devine aproape obligatorie aplicarea tehnicilor neparametrice.

4.4. Mărimea efectului

Mărimea efectului unei sau unor VI asupra VD reprezintă puterea relației dintre VI și VD sau mărimea diferenței între nivelele VI în ceea ce privește VD. Dacă testele statistice ne informează asupra semnificației statistice a unor rezultate, mărimea efectului este relevantă pentru semnificația practică a rezultatelor. Să presupunem că am obținut o corelație semnificativă între leadership și coeficientul de inteligență $r(498) = 0,100$, $p < 0,05$, însă cât de important este acest rezultat? În termenii coeficientului de determinare r^2 , vom spune că doar 1 % din varianța variabilei leadership este explicată de varianța variabilei IQ, ceea ce este extrem de puțin și practic nesemnificativ. Un alt avantaj al exprimării rezultatelor în termeni de mărime a efectului este faptul că rezultatele obținute în diferite cercetări, folosind diferite teste statistice și variabile măsurate pe diverse scale (nominale, ordinale, de intervale sau rapoarte) pot fi comparate între ele din punctul de vedere al mărimii efectelor și importanței acestora.

Specificarea mărimii efectului a devenit obligatorie odată cu ediția a cincea a manualului APA din 2001. Prima recomandare relativ la prezentarea mărimii efectelor în cadrul rezultatelor cercetării se regăsește în ediția a patra a manualului APA (1994), însă foarte puțini cercetători s-au conformat acestei cerințe; asta până în 1999, când Wilkinson și board-ul APA, în cadrul unui articol publicat în revista *American Psychologist*, fac precizarea că „întotdeauna trebuie prezentați indicatori ai mărimii efectului” atunci când expunem rezultatele unor cercetări (Wilkinson, The APA Task Force on Statistical Inference, 1999). Astfel, în ediția a șasea din 2003 a manualului APA, Asociația Psihologilor Americani stipulează că cercetătorii care doresc să publice în jurnalele de specialitate trebuie „să specifice în cadrul secțiunii *Rezultate* anumiți indicatori ai mărimii efectului precum r , r^2 , η^2 , R^2 , d al lui Cohen, V al lui Cramer” etc. (APA, 2003, p. 25).

Există două categorii de indicatori ai mărimii efectului: a) cei bazați pe o diferență standardizată între medii, precum indicatori d al lui Cohen, g al lui Hedges etc. și b) cei bazați pe procentul de varianță explicată, precum r , r^2 , η^2 etc. Cel mai adesea, cercetătorii prezintă mărimea efectului prin intermediul indicatorilor d sau r . Prezentăm mai jos formulele de calcul al acestor doi indicatori în cazul diferitelor teste (Cohen, 1988, Rosenthal, Rosnow și Rubin, 2000; Furr, 2005).

- Pentru testul t de comparare a unei medii cu o valoare standard fixată (*one-sample t-test*), formula de obținere a indicatorului d al lui Cohen este:

$$d = \frac{|\bar{X} - \mu|}{\sigma_X} \quad (4.1)$$

unde $\bar{X}$ este media variabilei pe eșantion

μ este media pe populație (sau valoarea de referință)

σ_X este deviația standard a variabilei pe eșantion.

- În cazul testului t pentru eșantioane perechi (*paired-sample t test*), formula de obținere a indicatorului d al lui Cohen este:

$$d = \frac{\bar{D}}{s_D} \quad (4.2.)$$

unde $\bar{D}$ este media diferențelor de scoruri

s_D este deviația standard a diferențelor de scoruri

- Pentru ambele teste prezentate mai sus (one-sample t test și paired-sample t test) formulele de obținere a indicatorilor d și r, precum și de transformare a lui d în r sunt:

$$d = \frac{t}{\sqrt{df}} = \frac{t}{\sqrt{N-1}} \quad (4.3) \quad r = \frac{t}{\sqrt{t^2 + df}} = \frac{t}{\sqrt{t^2 + (N-1)}} \quad (4.4)$$

$$d = \frac{r}{\sqrt{1-r^2}} \quad (4.5) \quad r = \frac{d}{\sqrt{d^2 + 1}} \quad (4.6)$$

- În cazul testului t pentru eșantioane independente, grupe inegale, formulele de calcul sunt:

$$d = \frac{|M_1 - M_2|}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \quad (4.7) \quad d = \frac{t(n_1 + n_2)}{\sqrt{df} \sqrt{n_1 n_2}} \quad (4.8)$$

$$r = \frac{t(n_1 + n_2)}{\sqrt{t^2(n_1 + n_2)^2 + 4df(n_1 n_2)}} \quad (4.9) \quad r = \frac{d \sqrt{n_1 n_2}}{\sqrt{d(n_1 n_2) + (n_1 + n_2)^2}} \quad (4.10)$$

unde n_1 reprezintă numărul de subiecți din primul grup iar n_2 numărul de subiecți din al doilea grup.

- În cazul testului t pentru eșantioane independente, grupe egale, formulele de calcul sunt:

$$d = \frac{2t}{\sqrt{df}} \quad (4.11) \quad r = \frac{\sqrt{d^2}}{d^2 + 4} \quad (4.12) \quad d = \frac{2r}{\sqrt{1-r^2}} \quad (4.13)$$

- Pentru teste neparametrice z sau χ^2 (cu $df = 1$), formula este:

$$r = \sqrt{\frac{z^2}{n}} = \sqrt{\frac{\chi^2(1)}{n}} \quad (4.14)$$

În interpretarea mărimii efectului ne vom ajuta de unele valori de referință stabilite de Cohen (1988) și prezentate în tabelul 4.1 de mai jos.

Tabelul 4.1. Interpretarea mărimii efectului

Mărimea efectului	d Cohen	r
foarte puternic	$\geq 1,00$	$\geq 0,70$
puternic	0,80	0,50
mediu	0,50	0,30
slab	0,20	0,10

Capitolul 5. Analiza corelațională

De multe ori, cercetătorii sunt interesați să verifice dacă există o corelație (asociere, legătură), o relație liniară între două sau mai multe variabile. Ne-ar putea interesa să verificăm, de exemplu, dacă există o relație între numărul de ore alocate studiului la matematică și notele elevilor la matematică.

Există mai multe tipuri de coeficienți de corelație utili în testarea corelației dintre două variabile: 1) coeficientul de corelație Pearson r ; 2) coeficientul de corelație Spearman ρ ; 3) coeficientul de corelație Kendall tau-b τ ; 4) coeficientul de corelație parțială. Primele trei tipuri se mai numesc și corelații bivariate.

Valorile coeficienților de corelație pot varia în intervalul $[-1, 1]$. O valoare a lui r pozitivă arată că există o *corelație pozitivă* între cele două variabile, astfel că odată cu creșterea orelor alocate studiului tinde să crească și performanța școlară. Atunci când r ia o valoare negativă, rezultă că există o *corelație negativă* între cele două variabile, astfel că, odată cu creșterea scorurilor la una dintre variabile, scorurile la cealaltă tind să scadă și reciproc. De exemplu, ar putea exista o corelație negativă între orele alocate jocurilor pe calculator și performanța școlară: elevii care alocă mai multe ore jocurilor pe calculator tind să obțină note școlare mai scăzute și invers, elevii care alocă mai puține ore jocurilor pe calculator tind să obțină note școlare mai ridicate. De asemenea, coeficienții de corelație pot lua și valoarea zero, iar în acest caz nu există o corelație între cele două variabile.

Vom discuta în continuare mai multe tipuri de analize corelaționale. *Scopul* acestor tehnici este verificarea asocierii, relației dintre două variabile, eventual controlând efectul unor alte variabile ce pot afecta relația dintre cele două supuse analizei.

5.1. Corelația Pearson și coeficientul de corelație r Pearson

5.1.1. Prezentare generală

Condițiile ce trebuie îndeplinite pentru calcularea coeficientului de corelație r Pearson sunt:

1. cele două variabile sunt cantitative;
2. variabilele sunt normal distribuite;
3. relația dintre variabile este liniară.


Exemple. 1. Verificăm dacă există o corelație pozitivă între numărul orelor pe săptămână alocate de elevi studiului la matematică și media școlară la obiectul matematică.
2. Analizăm dacă există o corelație între scorurile la un chestionar ce măsoară stima de sine și scorurile la un alt chestionar ce măsoară anxietatea.

5.1.2. Calcularea coeficientului de corelație r Pearson

Într-un studiu desfășurat pe elevi, analizăm dacă există o corelație pozitivă între variabilele *leadership* și *creativitate*. Vom aplica două chestionare ce măsoară comportamentele de leadership și creativitatea elevilor.


Deschidem fișierul *Corelație*. Mai întâi verificăm dacă sunt îndeplinite condițiile aplicării corelației Pearson. Prima condiție este îndeplinită, iar a doua poate fi ușor verificată. Verificarea condiției a treia o facem prin inspectarea grafică a norului de puncte.

Calea în SPSS este: *Graphs* → *Scatter* → *Simple* → *Define*. Trecem variabila *leadership* în câmpul *Y Axis*, iar variabila *creativitate* în câmpul *X Axis* și clic *OK*. În output va apărea graficul de mai jos.




Observăm că relația dintre cele două variabile este liniară și pozitivă. În plus, nu se observă existența unor cazuri extreme (în engleză, *outlier*) care ar putea distorsiona liniaritatea relației dintre cele două variabile (un asemenea caz ar fi fost un subiect care, de exemplu, ar fi obținut un scor foarte scăzut la creativitate (de exemplu, 45) și un scor foarte ridicat la leadership (de exemplu, 170), iar pe grafic ar fi fost localizat în colțul din stânga-sus. Un asemenea caz extrem nu ar fi urmat tendința de liniaritate respectată de celelalte cazuri din grafic și ar fi distorsionat valoarea coeficientului de corelație. Atunci când întâlnim asemenea cazuri extreme soluția cea mai simplă este eliminarea lor și recalcularea coeficientului de corelație.

Calea în SPSS pentru obținerea coeficientului de corelație r Pearson este: *Analyze* → *Correlate* → *Bivariate*.



Observăm că în câmpul *Correlation Coefficients* este bifată automat opțiunea *Pearson*, ceea ce înseamnă că va fi calculat coeficientul de corelație Pearson. În câmpul *Tests of Significance* este selectată automat opțiunea *Two-tailed* (specifică ipotezelor bidirecționale); cum ipoteza noastră este unidirecțională, vom selecta *One-tailed*. Trecem apoi în câmpul *Variables* din partea dreaptă variabilele *creativitate* și *leadership* și clic *OK*.



5.1.3. Interpretarea outputului

Din tabelul *Correlations*, observăm că există o corelație pozitivă semnificativă între leadership și creativitate, $r(102) = 0,660$, $p < 0,001$ (102 reprezintă gradele de libertate $df = N - 2$, unde N reprezintă numărul de subiecți). Cum coeficientul r este o mărime a efectului, conform lui Cohen (1988), rezultă că relația dintre creativitate și leadership este puternică.

Correlations

		leadership	creativitate
leadership	Pearson Correlation	1,000	,660**
	Sig. (2-tailed)	,	,000
	N	104	104
creativitate	Pearson Correlation	,660**	1,000
	Sig. (2-tailed)	,000	,
	N	104	104

** . Correlation is significant at the 0.01 level (2-tailed).

5.1.4. Prezentarea rezultatelor

Pentru a verifica dacă există o corelație pozitivă semnificativă între leadership și creativitate am calculat coeficientul de corelație r Pearson. Condiția normalității distribuției variabilelor a fost verificată prin intermediul testului Kolmogorov-Smirnov z , rezultatele obținute fiind, pentru variabila *leadership*, $K-S\ z = 0,579$, $p > 0,05$, iar pentru variabila *creativitate*, $K-S\ z = 0,729$, $p > 0,05$; cum ambele rezultate sunt nesemnificative statistic, rezultă că variabilele sunt normal distribuite. Condiția liniarității relației dintre cele două variabile a fost verificată prin inspectarea norului de puncte. Condițiile de aplicare fiind îndeplinite, am calculat coeficientul de corelație r Pearson. Conform rezultatelor obținute, există o corelație pozitivă între leadership și creativitate, $r(102) = 0,660$, $p < 0,001$; rezultă că elevii care obțin scoruri ridicate la leadership tind să obțină scoruri ridicate și la creativitate și reciproc. Cum r este o expresie a mărimii efectului, raportându-ne la criteriile lui Cohen (1988) rezultă că relația dintre creativitate și leadership este foarte puternică. Coeficientul de determinare este $R^2 = 0,43$, deci rezultă că 43% din varianța variabilei *leadership* este explicată de variabila *creativitate*.

5.2. Corelația Spearman și coeficientul de corelație ρ Spearman

5.2.1. Prezentare generală

Condițiile de aplicare a corelației ρ Spearman sunt :

1. variabilele sunt cantitative, însă nu sunt normal distribuite ;
2. ambele variabile sunt ordinale sau una este cantitativă, iar cealaltă ordinală ;
3. ambele variabile sunt cantitative însă eșantionul este de volum redus (de exemplu, 7 subiecți) ;


4. scorurile unei variabile sunt în mod monoton legate de scorurile celeilalte variabile, ceea ce înseamnă că, odată cu creșterea valorilor unei variabile, vor crește (sau descrește) și valorile celeilalte variabile (însă nu neapărat liniar).

Exemplu. Verificăm dacă există o corelație între ierarhizarea elevilor de către profesor de la 1 la 5 (1 = pe primul loc, 5 = pe ultimul loc) în ceea ce privește implicarea în sarcini extrașcolare și rezultatele elevilor la un chestionar care măsoară comportamentul prosocial.

5.2.2. Calcularea coeficientului de corelație ρ Spearman

Analizăm existența unei corelații între ierarhizarea elevilor dintr-o clasă de către profesor de la 1 la 5 (1 = pe primul loc, 5 = pe ultimul loc) în ceea ce privește aptitudinile matematice și rezultatele elevilor la un test de inteligență.

Deschidem fișierul *Corelație_Spearman*. În SPSS, calea este *Analyze* → *Correlate* → *Bivariate*. În câmpul *Correlation Coefficients* deselectionăm opțiunea *Pearson* și selectăm opțiunea *Spearman*, trecem variabilele *QI* și *evaluare profesor* în câmpul *Variables* din partea dreaptă, apoi clic *OK*.



5.2.3. Interpretarea outputului

Din tabelul *Correlations*, observăm că există o corelație negativă semnificativă între *QI* și evaluarea abilităților matematice, $\rho(26) = -0,714$, $p < 0,001$, ceea ce înseamnă că elevii care au un *QI* ridicat au scoruri scăzute la variabila *evaluare profesori* și invers. Ne amintim că un scor scăzut la variabila *evaluare profesori* înseamnă abilități matematice dezvoltate (primele locuri). Așadar, elevii evaluați de către profesori ca având abilități matematice dezvoltate au un *QI* ridicat și invers.


Cum toți coeficienții de corelație sunt expresii ale mărimii efectului (deci și p), raportându-ne la criteriile lui Cohen (1988), rezultă că relația dintre variabilele *QI* și *evaluare profesori* este foarte puternică.

Correlations

			evaluarea profesorului privind abilitatile matematice ale elevilor	QI
Spearman's rho	evaluarea profesorului privind abilitatile matematice ale elevilor	Correlation Coefficient	1,000	-,714**
		Sig. (2-tailed)	,000	,000
		N	28	28
QI	QI	Correlation Coefficient	-,714**	1,000
		Sig. (2-tailed)	,000	,000
		N	28	28

** Correlation is significant at the .01 level (2-tailed).

Verificarea condiției a patra se face prin intermediul inspectării norului de puncte, calea în SPSS fiind *Graphs → Scatter → Simple → Define*. Rezultatul este ilustrat în graficul de mai jos. Observăm că există o relație de descreștere monotonă între variabilele *QI* și *evaluare abilități matematice*.



5.3. Corelația Kendall și coeficientul de corelație Kendall τ


Condițiile de aplicare a corelației Kendall sunt:

1. ambele variabile sunt ordinale;
2. variabilele au un număr redus de categorii (de exemplu, 3) sau există un număr ridicat de ranguri egale.

5.3.1. Calcularea coeficientului de corelație Kendall τ

Să presupunem că delegăm unei clase de elevi o sarcină de grup, iar la finalul sarcinii evaluăm fiecare subiect după două dimensiuni: *implicarea în sarcină* (1 = puternică, 2 = medie, 3 = slabă) și *poziția în cadrul grupului* (1 = poziție de lider, 2 = poziție medie și 3 = poziție marginală). Vom verifica dacă există o corelație între cele două evaluări.

Deschidem fișierul *Corelație_Kendall*. Calea în SPSS este: *Analyze* → *Correlate* → *Bivariate*. În câmpul *Correlation Coefficients* deselectăm opțiunea *Pearson* și selectăm opțiunea *Kendall*, trecem variabilele *implicare* și *poziție* în câmpul *Variables* din partea dreaptă, apoi clic *OK*.



5.3.2. Interpretarea outputului

Rezultatele sunt prezentate în tabelul *Correlations* de mai jos. Observăm că există o corelație pozitivă semnificativă între implicarea elevilor în sarcină și poziția în cadrul grupului, $\tau(23) = 0,580$, $p < 0,01$, ceea ce înseamnă că elevii care se implică mai mult în sarcină tind să ocupe poziții centrale, de lider în grup, și invers, elevii care se implică mai puțin în sarcină tind să ocupe poziții marginale în cadrul grupului. În termenii mărimii efectului și conform criteriilor lui Cohen (1988), relația dintre cele două variabile este una puternică.

Correlations

			implicare in sarcina	pozitia in cadrul grupului
Kendall's tau_b	implicare in sarcina	Correlation Coefficient	1,000	,580**
		Sig. (2-tailed)	,	,003
		N	25	25
	pozitia in cadrul grupului	Correlation Coefficient	,580**	1,000
		Sig. (2-tailed)	,003	,
		N	25	25

** Correlation is significant at the .01 level (2-tailed).

5.4. Corelația parțială

5.4.1. Prezentare generală

Corelația parțială este corelația dintre două variabile în condiția menținerii constante a efectului altei (altor) variabile asupra celor două variabile analizate. Astfel, corelația parțială este utilă atunci când dorim să aflăm efectul pur (necontaminat) al unei variabile A asupra altei variabile B, eliminând (ținând sub control) efectele altor variabile asupra relației dintre A și B.


Condițiile ce trebuie îndeplinite pentru aplicarea corelației parțiale sunt :

1. variabilele sunt cantitative ;
2. variabilele sunt normal distribuite ;
3. relația dintre variabile este liniară.


Exemplu. Verificăm dacă există o corelație între numărul orelor pe săptămână alocate de elevi studiului la matematică și media școlară la obiectul matematică, menținând constant efectul coeficientului de inteligență.

5.4.2. Calcularea coeficientului de corelație parțială

Să analizăm dacă există o corelație între motivația și performanța școlară a elevilor în condiția în care menținem constant efectul coeficientului de inteligență al acestora. Deschidem fișierul *Corelatie_partiala*. Călea în SPSS este : *Analyze* → *Correlate* → *Partial*.



Trecem variabilele *performanță* și *motivație* în câmpul *Variables*, iar în câmpul *Controlling for* : trecem variabila *qi*. Activăm butonul *Options*, iar aici selectăm opțiunea *Zero-order correlations* pentru a vedea care sunt corelațiile dintre cele trei variabile fără eliminarea prealabilă a efectului variabilei *qi* asupra relației dintre celelalte două, apoi clic *Continue* și *OK*.



5.4.3. Interpretarea outputului

Rezultatele sunt prezentate mai jos. În prima parte este prezentată matricea corelațiilor Pearson dintre cele trei variabile (*Zero Order Partial*s). Acestea sunt corelațiile Pearson obișnuite dintre fiecare două variabile fără izolarea efectului celei de-a treia variabile. Corelațiile *r* Pearson obținute sunt : între performanță și motivație $r(93) = 0,60$, $p < 0,001$, între performanță și *QI* $r(93) = 0,71$, $p < 0,001$, iar între motivație și *QI* $r(93) = 0,52$, $p < 0,001$.

În a doua parte este prezentată corelația dintre performanță și motivație, controlând efectul variabilei *QI* (*Controlling for... QI*): $pr(92) = .38, p < .001$.

PARTIAL CORRELATION COEFFICIENTS

Zero Order Partials

	PERFORM	MOTIVAT	QI
PERFORM	1.0000	.6012	.7112
	(0)	(95)	(95)
	P= .	P= .000	P= .000
MOTIVAT	.6012	1.0000	.5205
	(95)	(0)	(95)
	P= .000	P= .	P= .000
QI	.7112	.5205	1.0000
	(95)	(95)	(0)
	P= .000	P= .000	P= .

(Coefficient / (D.F.) / 2-tailed Significance)

PARTIAL CORRELATION COEFFICIENTS

Controlling for.. QI

	PERFORM	MOTIVAT
PERFORM	1.0000	.3849
	(0)	(94)
	P= .	P= .000
MOTIVAT	.3849	1.0000
	(94)	(0)
	P= .000	P= .

(Coefficient / (D.F.) / 2-tailed Significance)

Observăm astfel că fără izolarea efectului variabilei *QI* corelația dintre motivație și performanță era 0,60 iar în urma izolării efectului variabilei *QI* corelația dintre motivație și performanță scade la 0,38. Așadar, ținând constantă influența coeficientului de inteligență asupra relației dintre motivație și performanță, există o corelație pozitivă semnificativă între motivație și performanță, $pr(92) = 0,38$. În termenii mărimii efectului și raportându-ne la criteriile lui Cohen (1988), efectul motivației asupra performanței (controlând efectul variabilei *QI*) este de nivel mediu.

Gradele de libertate în cazul corelației parțiale sunt date de formula $df = N - 2 - k$, unde *N* este volumul eșantionului, iar *k* reprezintă numărul de variabile ținute sub control. Vom putea astfel realiza o corelație parțială ținând sub control mai mult de o variabilă.

Exerciții SPSS

Analiza corelațională

1. Verificați corelațiile dintre variabila *performanță* și variabilele *motivație intrinsecă*, *motivație extrinsecă*, *autoeficiență*. Baza de date este *Corelatie_2*.
2. Verificați corelația dintre variabilele *performanță* și *motivație intrinsecă*, controlând efectul variabilei *autoeficiență*. Baza de date este *Corelatie_2*.

Capitolul 6. Teste t parametrice pentru comparare de medii

Testele t sunt teste de comparare a mediilor pentru variabile cantitative. Există trei tipuri de teste t :

- testul t pentru un eșantion (One-Sample T Test)
- testul t pentru două eșantioane independente (Independent-Samples T Test)
- testul t pentru două eșantioane perechi (Paired-Samples T Test).

6.1. Testul t pentru un eșantion (One-Sample T Test)

6.1.1. Prezentare generală

Aplicarea acestui test urmărește compararea mediei unei variabile cu o valoare standard fixată anterior. Se verifică astfel dacă există o diferență semnificativă între media pe eșantion și o valoare specificată a priori de către cercetător.

Condițiile aplicării testului t pentru un eșantion sunt :


1. variabila este cantitativă, măsurată pe scale de intervale sau proporții ;
2. variabila este normal distribuită ; unii autori consideră totuși că testele t sunt destul de robuste, putând fi aplicate și atunci când această condiție este încălcată.

Exemple. 1) Verificăm dacă media salariilor unui eșantion de femei de religie catolică diferă semnificativ de media salariilor femeilor în general. 2) Verificăm dacă există un stereotip al românilor față de romei pe dimensiunea *agresivi*, comparând media evaluărilor unui eșantion de români pe o scală în șapte trepte cu valoarea de mijloc 4.


6.1.2. Aplicarea testului t pentru un eșantion

Să analizăm dacă în urma unui examen de capacitate elevii dintr-o școală au obținut note semnificativ mai mari sau mai mici comparativ cu media pe județ la examenul de capacitate. Știm că media pe județ este 8,00.

Deschidem fișierul *One-sample_t_test*. Calea în SPSS este : *Analyze* → *Compare Means* → *One-Sample T Test*.



Trecem variabila *medie capacitate* în câmpul din dreapta *Test Variable(s)*, iar în câmpul *Test Value* trecem valoarea 8,00, apoi clic *OK*.



6.1.3. Interpretarea outputului

În tabelul *One-Sample Statistics* sunt prezentate informații privind numărul de subiecți (30), media obținută de aceștia la capacitate (6,80), deviația standard a acestei medii și eroarea standard a mediei. Comparând media obținută de subiecții noștri (6,80) cu media pe județ constatăm că elevii din eșantionul nostru au obținut o medie mai mică. Rămâne să vedem dacă această diferență (între 6,80 și 8,00) este și semnificativă statistic.

One-Sample Statistics

	N	Mean	Std. Deviation	Std. Error Mean
medie capacitate	30	6,80	1,86	,34

Tabelul *One-Sample Test* prezintă rezultatele la testul *t* de comparare a mediilor. Observăm că $t(29) = 3,525$, $p \leq 0,001$, ceea ce înseamnă că diferența dintre medii de 1,20 este semnificativă statistic¹. Tabelul prezintă și intervalul de încredere cu o probabilitate de 95% în care se încadrează diferența dintre medii. Observăm că valoarea zero nu aparține acestui interval, deoarece diferența dintre medii este semnificativă (dacă diferența nu era semnificativă, valoarea zero ar fi fost conținută în acest interval). Așadar, elevii din școala noastră au obținut rezultate semnificativ mai mici la examenul de capacitate, comparativ cu elevii din județ.

One-Sample Test

	Test Value = 8					
	t	df	Sig. (2-tailed)	Mean Difference	95% Confidence Interval of the Difference	
					Lower	Upper
medie capacitate	-3,525	29	,001	-1,20	-1,90	-,50

Calculând acum mărimea efectului conform formulei 4.4, obținem $r = 0,55$, ceea ce în termenii lui Cohen (1988) reprezintă un efect puternic.

6.2. Testul *t* pentru două eșantioane independente (Independent-Samples T Test)

6.2.1. Prezentare generală

Prin intermediul testului *t* pentru eșantioane independente verificăm dacă există diferențe semnificative între două grupuri comparate în ceea ce privește mediile variabilei dependente analizate. Acest test *t* este specific designurilor intergrupuri (*between groups*).

Condițiile aplicării testului t pentru eșantioane independente sunt :

1. independența grupurilor – fiecare subiect face parte doar dintr-un singur grup, iar aceste grupuri sunt independente ;
2. variabila dependentă este cantitativă, măsurată pe scale de interval sau proporții ;
3. variabila dependentă este normal distribuită ; unii autori consideră totuși că testele *t* sunt destul de robuste, putând fi aplicate și atunci când această condiție este încălcată ;
4. omogenitatea varianțelor – grupurile trebuie să facă parte din populații cu varianțe egale. Pentru testarea acestei condiții, SPSS folosește testul Levene. Dacă rezultatul la testul Levene este semnificativ ($p \leq 0,05$) atunci varianțele sunt inegale. Totuși, testul *t* este relativ robust la încălcarea acestei condiții, astfel că poate fi aplicat și în cazul unor varianțe inegale ; în această situație va fi citită o valoare ajustată a testului *t*.


1. În general, semnul la testele *t* nu se trece atunci când prezentăm rezultatele.

Exemplu. Verificăm dacă există diferențe semnificative între femei și bărbați în ceea ce privește sociabilitatea; VI este sex (nominală), iar VD este dată de scorurile la un chestionar de sociabilitate (variabilă cantitativă).


6.2.2. Aplicarea testului t pentru eșantioane independente

Să presupunem că într-o cercetare urmărim să verificăm dacă există diferențe semnificative între elevii provenind din familii cu un stil parental democratic și cei provenind din familii cu un stil autoritar în ceea ce privește motivația intrinsecă. VI este variabila *stil parental* (democratic-autoritar), iar VD este *motivație intrinsecă*.

Deschidem fișierul *Independent t test*. Calea în SPSS este *Analyze* → *Compare Means* → *Independent-Samples T Test*.



Trecem variabila VD *motivație intrinsecă* în câmpul *Test Variable(s)*, iar VI *stil parental* în câmpul *Grouping variable*, apoi clic pe butonul *Define groups*, definim grupurile trecând 1 și 2 (1 = „stil democratic” și 2 = „stil autoritar”), clic *Continue* și *OK*.



6.2.3. Interpretarea outputului

Tabelul *Group Statistics* prezintă pentru fiecare dintre cele două grupuri (stil parental democratic – stil parental autoritar) numărul de subiecți, media, deviația standard și eroarea standard a mediei. Observăm că media subiecților provenind din familii cu un stil parental democratic la variabila *motivație intrinsecă* este mai mare decât a celor provenind din familii cu un stil autoritar (35,17 comparativ cu 33,44).

Group Statistics

	stil parental	N	Mean	Std. Deviation	Std. Error Mean
motivație intrinsecă	stil democratic	42	35,17	3,86	,60
	stil autoritar	34	33,44	3,51	,60

Tabelul *Independent Samples Test* prezintă rezultatele la testul t de comparare a mediilor. Mai întâi citim rezultatele testului Levene: $F(74) = 0,142$, $p = 0,707$; cum F este nesemnificativ, varianțele sunt egale, iar condiția omogenității varianțelor este satisfăcută. *Varianțele fiind egale, citim rezultatele la testul t afișate pe rândul de sus.* Constatăm că $t(74) = 2,018$, $p = 0,047$, ceea ce înseamnă că există diferențe semnificative între medii, subiecții provenind din familii cu un stil democratic având în medie scoruri semnificativ mai mari la motivație intrinsecă comparativ cu cei provenind din familii cu un stil autoritar. În același tabel sunt prezentate diferența dintre medii (1,73), eroarea standard a diferenței și intervalul de încredere cu o probabilitate de 95% în care se încadrează această diferență. Atunci când în intervalul de încredere nu este conținută valoarea zero diferența dintre medii este semnificativă.

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
motivație intrinsecă	Equal variances assumed	,142	,707	2,018	74	,047	1,73	,85	2,20E-02	3,43
	Equal variances not assumed			2,039	72,949	,045	1,73	,85	3,87E-02	3,41

Calculând mărimea efectului cu ajutorul formulei (4.9) obținem $r = 0,23$, ceea ce înseamnă, conform criteriilor lui Cohen (1988), că stilului parental are o influență de nivel mediu asupra motivației intrinseci a copiilor.

Observație. Dacă rezultatul la testul Levene de omogenitate a varianțelor este semnificativ statistic, atunci vom citi și vom prezenta rezultatele ajustate la testul t și pragul de semnificație de pe rândul de jos în tabelul *Independent Samples Test*.

6.2.4. Prezentarea rezultatelor

În scopul verificării dacă motivația intrinsecă a elevilor diferă în funcție de stilul parental am aplicat testul t pentru eșantioane independente. Conform rezultatelor obținute (tabelul 6.1), există diferențe semnificative în funcție de stilul parental în ceea ce privește motivația intrinsecă a elevilor [$t(74) = 2,018$, $p = 0,05$]. Astfel, elevii care beneficiază de un stil parental democratic obțin în medie scoruri semnificativ mai mari la motivație intrinsecă ($M_1 = 35,17$) comparativ cu cei provenind din familii cu un stil autoritar ($M_2 = 33,44$). Conform criteriilor lui Cohen (1988), stilul parental are o influență de nivel mediu asupra motivației intrinseci a copiilor, $r = 0,23$.

Tabelul 6.1. Rezultatele la testul t de comparare a mediilor la variabila *motivație intrinsecă* în funcție de variabila *stil parental*

Variabile	n	M	SD	t	df	p
Motivație intrinsecă				2,018	74	0,047
Stil democratic	42	35,17	3,86			
Stil autoritar	34	33,44	3,51			

6.3. Testul t pentru două eșantioane perechi (Paired-Samples T Test)

6.3.1. Prezentare generală

Scop. Acest test urmărește compararea scorurilor a două variabile-pereche. Aplicarea acestui test urmează patru demersuri: 1) primul demers urmărește compararea scorurilor la o variabilă în două condiții experimentale pretest-posttest (de exemplu, performanță pretest și performanță posttest); 2) al doilea demers urmărește compararea scorurilor la o variabilă între două eșantioane corelate (de exemplu, valori părinți, valori copii); 3) al treilea demers urmărește compararea evaluărilor subiecților asupra a două aspecte diferite, scala de evaluare fiind aceeași (de exemplu, interesul privind două materii de învățământ diferite sau două produse diferite); 4) în fine, al patrulea demers este specific verificării fidelității unor instrumente de măsurare: a) fidelitate test-retest sau stabilitatea în timp și b) fidelitatea sau echivalența formelor paralele.

Aplicarea acestui test este specifică designurilor intragrupuri (within groups) sau cu măsurători repetate (*repeated measures*).

Condiții. Alături de condițiile generale se impun două condiții specifice.

1. VD este cantitativă, măsurată pe scale de intervale sau proporții;
2. VD este normal distribuită;
3. VI este dihotomică, iar nivelele sale (sau grupele) sunt pereche, sau legate într-un anumit mod (pretest-posttest, copii-părinți etc.);


4. Diferența de scoruri în populație urmează o distribuție normală – diferența dintre scorurile fiecărui subiect sau caz trebuie să fie normal distribuită, echivalent cu a spune că *VD urmează o distribuție normală în fiecare dintre condițiile VI*. De exemplu, trebuie să verificăm dacă VD este normal distribuită atât în condiția de pretest, cât și în cea de posttest. În general, această condiție este îndeplinită pe eșantioane mai mari de 30 de subiecți.

Exemplu. Verificăm eficiența unui program de training vizând dezvoltarea abilităților de comunicare la elevi (demersul 1, pretest-posttest). Aplicăm un chestionar care măsoară abilitățile de comunicare conținând două forme paralele A și B. Forma A este aplicată înainte de training (pretest), iar forma B este aplicată după training (posttest). VI este *momentul temporal* (cu două nivele : înainte de intervenție și după intervenție), iar VD e reprezentată de *abilitățile de comunicare*.


6.3.2. Aplicarea testului t pentru eșantioane perechi

Ne propunem să analizăm eficiența unui program de intervenție care urmărește creșterea stimei de sine școlare la elevi. Vom măsura stima de sine școlară a elevilor înainte de derularea programului și apoi după derularea programului (pretest-posttest).

Deschidem fișierul *Perechi_t_test*. Calea în SPSS este : *Analyze* → *Compare Means* → *Paired-Samples T Test*.



Cele două variabile-pereche sunt *ssi* (stima de sine înainte de intervenție) și *ssd* (stima de sine după intervenție). Bifăm cele două variabile și le trecem în câmpul *Paired Variables* apoi clic *OK*.



6.3.3. Interpretarea outputului

Tabelul *Paired Samples Statistics* afișează – pentru fiecare dintre cele două variabile – mediile, numărul de subiecți, deviațiile standard și erorile standard ale mediilor. Observăm că media la stima de sine înainte de intervenție este 37,56, iar după intervenție este 45,04.

Paired Samples Statistics

		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	stima de sine scolara inainte de interventie	37,56	25	8,52	1,70
	stima de sine scolara dupa interventie	45,04	25	6,59	1,32

Tabelul *Paired Samples Correlation* prezintă coeficientul de corelație dintre cele două variabile $r(23) = 0,748$ și pragul de semnificație asociat $p = 0,000 (< 0,05)$.

Paired Samples Correlations

		N	Correlation	Sig.
Pair 1	stima de sine scolara inainte de interventie & stima de sine scolara dupa interventie	25	,748	,000

Ultimul tabel, *Paired Samples Test*, prezintă rezultatele testului t , $t(24) = 6,602$, $p = 0,000$. Cum t este semnificativ, rezultă că există o diferență semnificativă între cele două condiții înainte-după, stima de sine a subiecților după intervenție fiind semnificativ mai mare comparativ cu stima de sine înainte de intervenție. Tabelul mai prezintă media diferențelor de medie pentru perechea de variabile luate în calcul ($-7,48$), deviația standard, eroarea standard a mediei și limitele intervalului de încredere în care se încadrează această medie (cu o probabilitate de 95%). Un alt mod de a afla dacă diferența este semnificativă este să urmărim în ce măsură intervalul de încredere conține valoarea zero: dacă zero este conținut, diferența este nesemnificativă.

Paired Samples Test

		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	stima de sine scolara inainte de interventie - stima de sine scolara dupa interventie	-7,48	5,67	1,13	-9,82	-5,14	-6,602	24	,000

Calculând mărimea efectului cu ajutorul formulei (4.3), obținem $d = 0,80$; prin urmare, programul de intervenție a avut un efect foarte puternic asupra creșterii stimei de sine a elevilor.

Observație. Atunci când verificăm fidelitatea unor teste sau chestionare (demersul 4), trebuie îndeplinite condițiile: 1) coeficientul de corelație să fie ridicat (superior valorii 0,70) și 2) rezultatele la testul t să fie nesemnificative statistic ($p > 0,05$).

Exerciții SPSS

Teste t parametrice

1. Deschideți fișierul *Agresivitate_test-retest*. Verificați dacă vizionarea de jocuri agresive pe calculator a avut efect asupra creșterii agresivității subiecților.
2. Deschideți fișierul *QI*. Verificați dacă media scorurilor la QI pe eșantionul testat este mai mare sau mai mică comparativ cu valoarea medie pe populație, 100.
3. Deschideți fișierul *Independent_t_test*. Verificați dacă există diferențe semnificative între elevii provenind din familii cu un stil parental democratic și cei din familii cu un stil autoritar în ceea ce privește motivația extrinsecă și autoeficiența.
4. Deschideți fișierul *Emisiuni_tv*. Verificați dacă elevii preferă semnificativ mai mult emisiunile TV de divertisment, comparativ cu emisiunile TV culturale.

Capitolul 7. Teste neparametrice pentru un eșantion


7.1. Testul binomial de verificare a egalității unei proporții cu o valoarea specificată

Scopul testului binomial este de a compara o proporție cu o valoare specificată. Putem verifica, de exemplu, dacă un eșantion este reprezentativ în funcție de o serie de variabile dihotomice precum *gen* sau *mediul de rezidență*. Acest test este varianta neparametrică a testului t pentru un eșantion.

Testul binomial probează egalități de proporții sau egalitatea unei proporții observate cu una specificată.


7.1.1. Aplicarea testului binomial

Vom verifica dacă proporția de bărbați și femei dintr-un eșantion diferă semnificativ de 0,50. Deschidem fișierul *Binomial_test*. Călea în SPSS este : *Analyze* → *Nonparametric test* → *Binomial*.



Trecem variabila *gen* în câmpul din stânga *Test Variable List*, ne asigurăm că în câmpul *Test Proportion* este trecută valoarea 0,50, apoi că în câmpul *Define Dichotomy* este selectată opțiunea *Get from data* și clic *OK*. Dacă intenționăm să modificăm proporția de referință, trecem în câmpul *Test Proportion* proporția cu care dorim comparăm datele de care dispunem.

Opțiunea *Cut point* este utilă atunci când analizăm o variabilă cantitativă pe care dorim să o dihotomizăm. De exemplu, cunoscând media la variabila *motivație*, am putea fi interesați dacă proporția de elevi dintr-un eșantion testat având scoruri la motivație sub medie diferă semnificativ de proporția celor având scoruri peste medie.



7.1.2. Interpretarea outputului

Rezultatele obținute sunt prezentate în tabelul *Binomial Test*. În coloana *N* sunt trecute frecvențele reale ale bărbaților și femeilor din eșantionul nostru : observăm că sunt 91 de femei și 21 de bărbați. Coloana *Observed Prop.* prezintă proporțiile după variabila *gen* din eșantion ; cei 21 de bărbați reprezintă 19% din totalul de 112 subiecți testați. În coloana *Test Prop.* este prezentată proporția de referință cu care se compară proporția de bărbați-femei din eșantion. Cum pragul de semnificație este $< 0,05$ ($p = 0,000$) rezultă că femeile predomină într-o măsură semnificativ mai mare comparativ cu bărbații în eșantionul testat.

Binomial Test

	Category	N	Observed Prop.	Test Prop.	Asymp. Sig. (2-tailed)
GEN	Group 1	feminin	91	,81	,000 ^a
	Group 2	masculin	21	,19	
	Total	112	1,00		

a. Based on Z Approximation.

7.2. Testul χ^2 de ajustare sau potrivire (goodness of fit)

7.2.1. Prezentare generală

Scopul principal este de a compara un set de frecvențe observate cu un set de frecvențe teoretice (frecvențe teoretice care pot fi egale pentru fiecare categorie sau specificate de către cercetător). Testul este folosit frecvent în verificarea reprezentativității unui eșantion (frecvențele teoretice vor fi specificate) sau descoperirea unor preferințe/opinii conturate față de un produs (frecvențele teoretice nu vor fi specificate, vor fi considerate egale).

Condițiile de aplicare pentru testul χ^2 de ajustare sunt :

1. observațiile sunt independente (fiecare subiect este considerat în analiză doar o singură dată) ;
2. variabila analizată este categorială.


Există două situații specifice aplicării acestui test :

- a) când cercetătorul nu dispune de frecvențele teoretice anterioare privind distribuția variabilei analizate, caz în care vorbim despre aplicarea testului χ^2 de ajustare pentru frecvențe teoretice egale ;
- b) când cercetătorul dispune de frecvențe teoretice anterioare, caz în care vorbim despre aplicarea testului χ^2 de ajustare pentru frecvențe teoretice specificate.


Exemple. 1) Verificăm dacă eșantionul pe care s-a realizat standardizarea unui test este reprezentativ în funcție de variabila *categoriei de vârstă*. Frecvențele teoretice sunt specificate pe baza datelor demografice cunoscute în populație. Dacă frecvențele observate diferă semnificativ de cele expectate (teoretice) – χ^2 fiind semnificativ –, atunci eșantionul nu este reprezentativ. În același mod se verifică și dacă eșantionul pe care s-a realizat un sondaj de opinie este reprezentativ în funcție de anumite variabile. 2) Verificăm dacă există o preferință conturată a elevilor pentru una dintre următoarele tipuri de emisiuni TV : de informare, culturale, de divertisment. Frecvențele teoretice vor fi egale și specificate automat de SPSS (nu vor fi introduse de cercetător, ca în primul exemplu). Un χ^2 semnificativ indică o conturare a preferinței în direcția reziduurilor celor mai mari în valoare absolută.

7.2.2. Aplicarea testului χ^2 de ajustare

Vom verifica importanța acordată anumitor instituții în formarea caracterului de către un lot de subiecți elevi de liceu. Deschidem fișierul *Chi_patrat_ajustare*. Calea în SPSS este : *Analyze* → *Nonparametric test* → *Chi Square*.



Trecem variabila *caracter* în câmpul *Test Variable List*. Deoarece atunci când analizăm conturarea unor preferințe sau opinii frecvențele teoretice nu sunt specificate de cercetător, în câmpul *Expected Value* vom lăsa bifată opțiunea standard *All categories equal*, apoi clic *OK*.



7.2.3. Interpretarea outputului

În primul tabel sunt prezentate pentru fiecare categorie frecvențele observate, frecvențele așteptate (teoretice) și reziduurile.

Care dintre următoarele institutii are o influenta mai mare asupra formarii caracterului elevilor?

	Observed N	Expected N	Residual
mass-media	12	20,7	-8,7
familia	14	20,7	-6,7
scoala	36	20,7	15,3
Total	62		

Următorul tabel, *Test Statistics*, prezintă rezultatele la testul χ^2 . Observăm că $\chi^2 (2) = 17,161$ este semnificativ, $p = 0,000$, ceea ce înseamnă că există o opinie conturată în eșantionul nostru în ceea ce privește ponderea diferitelor instituții în formarea caracterului.

Test Statistics

	Care dintre următoarele institutii are o influenta mai mare asupra formarii caracterului elevilor?
Chi-Square ^a	17,161
df	2
Asymp. Sig.	,000

a. 0 cells (.0%) have expected frequencies less than 5. The minimum expected cell frequency is 20,7.

Pentru a vedea în ce sens este conturată opinia, inspectăm reziduurile din primul tabel; opinia va fi conturată în direcția reziduurilor celor mai mari în valoare absolută. În cazul nostru, reziduurile cele mai mari sunt în cazul categoriei *școala*. Prin urmare, elevii consideră că școala are o pondere semnificativ mai mare în formarea caracterului comparativ cu mass-media și familia.

Observații :

1. Dacă frecvențele teoretice sunt specificate de către cercetător, în câmpul *Expected Value* bifăm opțiunea *Value*, apoi introducem în ordine frecvențele așteptate – ordinea corespunzând creșterii nivelului variabilei analizate : prima frecvență așteptată introdusă corespunde nivelului 1 al variabilei; clic pe butonul *Add*, apoi introducem frecvența așteptată corespunzătoare nivelului 2 etc.
2. Gradele de libertate $df = (\text{numărul de categorii} - 1)$.
3. Reziduurile reprezintă diferența dintre frecvențele așteptate și cele observate.
4. Când numărul de trepte ale variabilei crește, repartitia poate fi cercetată mai precis cu ajutorul analizelor două câte două, prin intermediul testului binomial.

Capitolul 8. Măsurile de asociere pentru tabele încrucișate (*crosstabulations*)

8.1. Testul χ^2 de asociere sau independență pentru analiza datelor categoricale

8.1.1. Prezentare generală

Scopul aplicării testului χ^2 este verificarea asocierii dintre două variabile nominale, categoricale sau compararea de frecvențe între două eșantioane independente.

Testul χ^2 calculează diferența dintre frecvențele observate și cele așteptate pentru fiecare dintre celulele tabelului de încrucișare a celor două variabile. Dacă diferențele sunt nule, atunci cele două variabile sunt independente, iar dacă diferențele sunt mari, atunci rezultatul la testul χ^2 tinde să fie semnificativ statistic și prin urmare am putea spune ceva despre gradul de asociere a celor două variabile.

Condițiile aplicării testului χ^2 sunt :

1. variabilele sunt nominale, categoricale ;
2. observațiile sunt independente ;
3. categoriile sunt mutual exclusive – nici un participant nu poate fi în mai mult decât o celulă ;
4. numărul minim de frecvențe așteptate pentru o celulă trebuie să fie mai mare sau egal cu 5 ; dacă asumția este încălcată, vom păstra valoarea calculată la testul χ^2 și o vom raporta la pragul de semnificație ajustat prin metoda Fisher calculat automat de SPSS (Dancey și Reidy, 2002).


8.1.2. Aplicarea testului χ^2

Verificăm dacă există diferențe semnificative între subiecții care au avut contacte culturale cu indivizi din alte culturi și subiecții care nu au avut asemenea contacte (tabelul 8.1). Variabila independentă este *contacte culturale* (variabilă cu două categorii : *nu a avut contacte culturale* versus *a avut contacte culturale*), iar variabila dependentă este *distanța socială* (variabilă cu două categorii : *ridicăta* versus *scăzută*).


Tabelul 8.1. Relația dintre existența unor contacte culturale și distanța socială

		Existența unor contacte culturale	
		Nu	Da
Distanța socială	Scăzută	10	23
	Ridicată	20	7

Deschidem fișierul *Chi_patrat_independenta*. Calea în SPSS este : *Analyze* → *Descriptive Statistics* → *Crosstab*.



Trecem variabila *distanță* în câmpul *Row(s)*, iar variabila *contacte* în câmpul *Column(s)*.



Activăm butonul *Statistics*, iar aici bifăm *Chi-square* și *Phi and Cramer's V* (coeficientul *V* al lui Cramer este un indicator al mărimii efectului), apoi clic *Continue*.

Crosstabs: Statistics

☒ Chi-square

☐ Correlations

☐ Nominal

☐ Contingency coefficient

☒ Phi and Cramer's V

☐ Gamma

☐ Lambda

☐ Somers' d

☐ Uncertainty coefficient

☐ Kendall's tau-b

☐ Kendall's tau-c

☐ Nominal by Interval

☐ Kappa

☐ Eta

☐ Risk

☐ McNemar

☐ Cochran's and Mantel-Haenszel statistics

Test common odds ratio equals:

Continue

Cancel

Help

Activăm apoi butonul *Cells*, iar în câmpul *Residuals* bifăm *Adj. Standardized* și de asemenea în câmpul *Percentages* avem trei opțiuni pentru prezentarea procentelor (fie pe linii, fie pe coloane, fie per total) ; în acest caz vom bifa opțiunea *Column* (deoarece *VI* este trecută pe coloane), apoi clic *Continue* și *OK*.

Crosstabs: Cell Display

Counts

☒ Observed

☒ Expected

Percentages

☐ Row

☒ Column

☐ Total

Residuals

☐ Unstandardized

☐ Standardized

☒ Adj. standardized

Continue

Cancel

Help

8.1.3. Interpretarea outputului

Tabelul *Crosstabulation* prezintă frecvențele observate pentru fiecare dintre cele patru celule rezultate din încrucișarea variabilelor noastre, frecvențele așteptate (teoretice), procentele pe linii, frecvențele totale pe linii și coloane, precum și reziduurile ajustate pentru fiecare celulă.

distanța socială * existența unor contacte culturale Crosstabulation

			existența unor contacte culturale		Total
			nu	da	
distanța socială	scăzută	Count	10	23	33
		Expected Count	16,5	16,5	33,0
		% within existența unor contacte culturale	33,3%	76,7%	55,0%
		Adjusted Residual	-3,4	3,4	
	ridicată	Count	20	7	27
		Expected Count	13,5	13,5	27,0
		% within existența unor contacte culturale	66,7%	23,3%	45,0%
		Adjusted Residual	3,4	-3,4	
Total		Count	30	30	60
		Expected Count	30,0	30,0	60,0
		% within existența unor contacte culturale	100,0%	100,0%	100,0%

Observăm că dintre cei 33 de subiecți care manifestă o distanță socială scăzută, 10 (sau 33,3%) nu au avut contacte culturale, iar 23 (sau 76,7%) au avut contacte culturale cu persoane din alte culturi. De asemenea, dintre cei 27 de subiecți care manifestă o distanță socială ridicată, 20 (sau 66,7%) nu au avut contacte culturale, iar 7 (sau 23,3%) au avut contacte culturale cu persoane din alte culturi.

Tabelul *Chi-Square Tests* conține informațiile cele mai importante, respectiv rezultatele la testul χ^2 . Observăm că $\chi^2(1) = 11,380$, $p = 0,001$; așadar, există o interdependență semnificativă statistic între cele două variabile.

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	11,380 ^b	1	,001		
Continuity Correction ^a	9,697	1	,002		
Likelihood Ratio	11,789	1	,001		
Fisher's Exact Test				,002	,001
Linear-by-Linear Association	11,191	1	,001		
N of Valid Cases	60				

a. Computed only for a 2x2 table

b. 0 cells (,0%) have expected count less than 5. The minimum expected count is 13,50.

Atunci când χ^2 este semnificativ, pentru a interpreta sensul interdependenței sau asocierii vom reveni la tabelul *Crosstabulation*, unde vom inspecta reziduurile standardizate ajustate : dacă valorile acestora nu se găsesc în intervalul $[-2, 2]$ rezultă că există o diferență semnificativă între valorile observate și cele așteptate (Sava, 2004). Constatăm că toate cele patru reziduuri depășesc limitele intervalului $[-2, 2]$, prin urmare, în cadrul fiecărei celule, există o diferență semnificativă între valorile observate și cele așteptate (analiza reziduurilor ne ajută mult atunci când una dintre variabile are mai mult de două categorii). În interpretare ne vom ajuta și de procente pe linie. Observăm că, odată cu trecerea de la inexistența la existența unor contacte culturale numărul indivizilor care manifestă o distanță socială scăzută tinde să crească (de la 33,3% la 76,7%), iar numărul indivizilor care manifestă o distanță socială ridicată tinde să se reducă (de la 66,7% la 23,3%).

Așadar, distanța socială ridicată tinde să fie asociată cu inexistența unor contacte culturale, iar distanța socială scăzută tinde să fie asociată cu existența unor contacte culturale.

8.1.4. Mărimea efectului

Indicatori ai mărimii efectului sunt oferiți în ultimul tabel, *Symmetric Measures* : *coeficientul phi* (pentru tabele 2×2 ; valoarea acestuia va fi citită și interpretată în valoare absolută) și *coeficientul V al lui Cramer* (dacă una dintre cele două variabile conține mai mult de două categorii, de exemplu pentru tabele 2×3); aceștia sunt coeficienți interpretabili asemenea coeficientului de corelație r Pearson. Deoarece $\phi = 0,436$, raportându-ne la criteriile lui Cohen (1988), vom spune că existența/inexistența unor contacte culturale are o influență moderată asupra distanței sociale.

Symmetric Measures

		Value	Approx. Sig.
Nominal by	Phi	,436	,001
Nominal	Cramer's V	,436	,001
N of Valid Cases		60	

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

Indicatorul ϕ de evaluare a mărimii efectului poate fi calculat și manual, cunoscând valoarea testului χ^2 și volumul eșantionului.


$$\phi = \sqrt{\frac{\chi^2}{N}} = \sqrt{\frac{11,380}{60}} = 0,436$$

Evaluarea mărimii efectului se face prin raportare la următoarele praguri :


Coefficientul Phi	Mărimea efectului
mai mic de 0,10	slab
între 0,10 și 0,30	modest
între 0,30 și 0,50	moderat
între 0,50 și 0,80	puternic
peste 0,80	foarte puternic

8.1.5. Prezentarea grafică a rezultatelor


Pentru a obține o ilustrare grafică a rezultatelor vom proceda după cum urmează.




În meniul *Graphs* → *Bar* vom alege opțiunea *Clustered* și vom lăsa selectată opțiunea *Summaries for groups of cases* ; apoi clic pe butonul *Define*.




Vom trece variabila *distanța socială* în câmpul *Category Axis*, iar variabila *existența unor contacte culturale* în câmpul *Define Clusters by*. Vom lăsa activată opțiunea *N of cases*, apoi clic *OK*.



În output vom face dublu-clic pe graficul obținut și vom obține o nouă fereastră, *Chart1 – SPSS Chart Editor*. Aici vom face clic pe butonul , se va deschide o nouă fereastră *Bar label Styles*, în care vom selecta opțiunea *Framed*, clic pe butonul *Apply All*, apoi clic *Close* și închidem fereastra *Chart1 – SPSS Chart Editor*.



Reprezentarea grafică va arăta astfel :



8.1.6. Considerații finale

Dintre cele două variabile, pe care o vom trece pe linii și pe care pe coloane ?

Ca regulă generală, variabila independentă (VI) o vom trece pe coloană, iar variabila dependentă (VD) pe linie. Aceasta este însă doar o convenție și nu afectează rezultatele testului de independență. Uneori, nu avem o ipoteză pe baza căreia să stabilim care este VI și care este VD (de exemplu, dacă am verifica asocierea/independența dintre variabilele *gen* și *religie*).

Observații :

1. Pentru tabele 2×2 și eșantioane de volum redus vom raporta coeficientul Pearson χ^2 și pragul de semnificație afișat de Fisher's exact test. De exemplu (deși nu este cazul aici): $\chi^2(1) = 11,380, p = 0,002$.
2. Atunci când pentru tabele cu mai mult de două categorii una dintre celule conține zero frecvențe observate, ar trebui ca respectiva categorie să fie unită cu alta ; se recomandă ca volumul eșantionului să fie suficient de mare pentru a fi siguri că avem suficiente frecvențe observate în fiecare celulă.
3. Atunci când asocierea este semnificativă, în cazul tabelelor 2×2 putem spune ceva și despre direcția relației, privind celulele.
4. Gradele de libertate pentru încrucișarea a două variabile A și B sunt date de formula $df = (\text{numărul de categorii ale variabilei A} - 1) \times (\text{numărul de categorii ale variabilei B} - 1)$.
5. Pentru un test χ^2 cu un singur grad de libertate (tabele 2×2), ipotezele pot fi și unidirecționale ; dacă $df > 2$, ipotezele pot fi numai bidirecționale (Sava, 2004)

6. Cu cât numărul de categorii crește, cu atât interpretarea este mai dificilă. Pentru un număr mare de celule se recomandă două soluții : a) condensăm anumite categorii ale variabilelor sau facem comparații doar pe anumite celule care ne interesează în mod special ; b) aplicăm tehnici de analiză mai complexe precum ANACOR (analiza de corespondență).

8.1.7. Prezentarea rezultatelor

Pentru a verifica dacă distanța socială diferă în funcție de existența/inexistența unor contacte culturale am aplicat testul χ^2 de asociere. În tabelul 8.2 sunt prezentate rezultatele la testul Pearson χ^2 , rezultând că distanța socială diferă în funcție de existența/ inexistența unor contacte culturale [$\chi^2(1) = 11,380$, $p < 0,001$]. Subiecții care au avut contacte culturale anterioare cu indivizi din alte culturi tind să manifeste o distanță socială scăzută, în vreme ce aceia care nu au avut asemenea contacte tind să manifeste o distanță socială ridicată. Indicatorul mărimii efectului, coeficientul $\phi = 0,436$, ceea ce conform lui Cohen (1988) înseamnă că relația dintre cele două variabile este moderată.

Tabelul 8.2. Analiza chi-pătrat privind manifestarea distanței sociale în funcție de existența/ inexistența unor contacte culturale

Variabile	n	Distanță socială		χ^2	df	p
		scăzută	ridicăată			
Contacte culturale				11,380	1	0,001
Nu	30	10	20			
Da	30	23	7			
Total	60	33	27			

8.2. Teste de asociere cu o variabilă nominală și una ordinală

8.2.1. Prezentare generală

Măsurarea asocierii dintre două variabile vizează gradul în care o schimbare în valorile unei variabile este legată de o schimbare în valorile celeilalte variabile.

Decizia de a aplica unul sau altul dintre testele de asociere depinde de răspunsul pe care cercetătorul îl dă la întrebarea „Care este variabila dependentă și care este variabila independentă?”. Atunci când avem motive să afirmăm că una dintre variabile este independentă, iar cealaltă dependentă suntem în situația aplicării testelor *asimetrice*. Dacă, pe de altă parte, relația dintre cele două variabile este de dependență reciprocă sau pur și simplu nu știm care dintre variabile este independentă și care dependentă, atunci există o relație de *simetrie* între variabile, iar testele aplicate vor fi teste *simetrice*. Prezentăm în continuare un tabel sintetic privind alegerea testelor de asociere în funcție de gradul de asimetrie-simetrie și scala de măsurare a variabilelor.

Tabelul 8.3. Măsuri ale asocierii (Argyrous, 2005)

Măsurarea	Simetrie	Scala de măsurare	Observații
Lambda	asimetrie	Cel puțin una dintre variabile este nominală	Poate subestima puterea relației dacă una dintre variabile este ordinală sau măsurată pe scale de interval/proporții
Goodman și Kruskal tau	asimetrie	Cel puțin una dintre variabile este nominală	
Eta	asimetrie	Recomandat dacă variabila independentă este nominală, iar variabila dependentă este măsurată pe scale de interval/proporții	Funcționează după o logică similară cu coeficientul de corelație Pearson r
d al lui Sommer	asimetrie	Ambele variabile sunt cel puțin ordinale	
Gamma	simetrie	Ambele variabile sunt cel puțin ordinale	Nerecomandat pentru relații neconsistente
Tau- b al lui Kendall	simetrie	Ambele variabile sunt cel puțin ordinale	Recomandat doar pentru tabele cu același număr de linii și coloane
Tau- c al lui Kendall	simetrie	Ambele variabile sunt cel puțin ordinale	
Rho al lui Spearman	simetrie	Ambele variabile sunt cel puțin ordinale, cu mai multe trepte pe scală	
r al lui Pearson	simetrie	Ambele variabile sunt măsurate pe scale de interval/proporții, cu mai multe trepte pe scală	Recomandat pentru relații liniare

Toate aceste teste le găsim în comanda *Crosstabs-Statistics* din SPSS.


8.2.2. Aplicarea testelor de asociere pentru o variabilă nominală și una ordinală

Să analizăm dacă există o asociere între repetarea cursului înainte de examen și rezultatele obținute de către studenți la examen. Datele pe care le vom analiza sunt cele din tabelul de mai jos. Vom calcula valoarea Lambda privind asocierea dintre cele două variabile.


Tabelul 8.4. Relația dintre repetarea cursului și rezultatele la examen

		Repetarea cursului cu o zi înainte de examen	
		Da	Nu
Rezultate examen	Performanțe scăzute	10	28
	Performanțe medii	21	23
	Performanțe ridicate	48	11

Deschidem fișierul *repetare curs*. Calea în SPSS este: *Analyze* → *Descriptive Statistics* → *Crosstab*. Deoarece știm că Lambda este un indicator statistic destinat analizării datelor asimetrice, iar conform datelor noastre, rezultatele la examen depind de repetarea cursului, VI este *repetare*, iar VD este *rezultate*; prin urmare, vom trece variabila *repetare* pe coloane, iar variabila *rezultate* pe linii.



Activăm butonul *Statistics*, iar în caseta care rezultă bifăm Lambda apoi clic *Continue*.



Activăm apoi butonul *Cells*, în câmpul *Residuals* bifăm *Adj. Standardized* și, de asemenea, în câmpul *Percentages* bifăm opțiunea *Column* (deoarece VI este trecută pe coloane), apoi clic *Continue* și *OK* (similar cu testul χ^2 prezentat anterior).

8.2.3. Interpretarea outputului

Interpretarea rezultatelor din tabelul *Crosstabulation* se face la fel ca în cazul testului χ^2 . Observăm că, dintre cei 79 de studenți care au repetat cursul înainte de examen, 10 (sau 12,7%) au obținut performanțe scăzute la examen, 21 (sau 26,6%) performanțe medii și 48 (sau 60,8%) performanțe ridicate. De asemenea, dintre cei 62 de studenți care nu au repetat cursul înainte de examen, 28 (sau 45,2%) au obținut performanțe scăzute la examen, 23 (sau 37,1%) performanțe medii și numai 11 (sau 17,7%) performanțe ridicate. Pe baza acestor rezultate observăm că există o asociere între repetarea cursului și performanța la examen, în sensul că studenții care repetă cursul cu o zi înainte de examen tind să obțină mai degrabă performanțe ridicate, iar cei care nu repetă cursul tind să obțină performanțe scăzute. Pentru a verifica dacă această asociere este semnificativă statistic vom inspecta tabelul *Directional Measures*.

performante examen * repetarea cursului înainte de examen Crosstabulation

			repetarea cursului inainte de examen		Total
			da	nu	
performante examen	performante scazute	Count	10	28	38
		% within repetarea cursului inainte de examen	12,7%	45,2%	27,0%
		Adjusted Residual	-4,3	4,3	
	performante medii	Count	21	23	44
		% within repetarea cursului inainte de examen	26,6%	37,1%	31,2%
		Adjusted Residual	-1,3	1,3	
	performante ridicate	Count	48	11	59
		% within repetarea cursului inainte de examen	60,8%	17,7%	41,8%
		Adjusted Residual	5,1	-5,1	
Total	Count	79	62	141	
	% within repetarea cursului inainte de examen	100,0%	100,0%	100,0%	

În tabelul *Directional Measures* urmărim valoarea lui Lambda (termenul *măsuri direcționale* este folosit de SPSS pentru măsurarea relațiilor de asociere asimetrice). Tabelul prezintă trei versiuni ale lui Lambda: simetric, asimetric având *performante examen* ca variabilă dependentă și asimetric având *repetarea cursului* ca variabilă dependentă.

Directional Measures

			Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Nominal by Nominal	Lambda	Symmetric	,257	,080	2,861	,004
		performante examen	,207	,068	2,797	,005
		Dependent	,323	,120	2,248	,025
	Goodman and Kruskal tau	performante examen	,114	,037		,000 ^c
		Dependent	,214	,065		,000 ^c
		repetarea cursului înainte de examen				

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

c. Based on chi-square approximation

Vom lua în calcul versiunea simetrică atunci când nu avem nici un motiv să considerăm că una dintre variabile este dependentă, iar cealaltă dependentă. Vom lua în calcul versiunile asimetrice atunci când avem motive să considerăm că una dintre variabile este dependentă, iar cealaltă independentă. În cazul de față, deoarece *performanțele la examen* este variabila dependentă, ne vom raporta la valoarea Lambda de 0,207 și pragul de semnificație adiacent. Așadar, $\lambda = 0,207$, $p = 0,005$. Tabelul mai prezintă și valorile unui alt coeficient de asociere a variabilelor nominale, *tau* al lui Goodman și Kruskal.

8.2.4. Considerații finale privind Lambda

Valorile lui Lambda variază între 0 și 1, 0 semnificând inexistența asocierii dintre variabile, iar 1 asocierea perfectă între variabile. Există o serie de valori la care ne vom raporta în interpretarea importanței asocierii dintre variabile în funcție de valorile Lambda.

Tabelul 8.5. Interpretarea valorilor Lambda (Argyrous, 2005)

Valori	Mărimea efectului
0,0	Inexistența relației dintre variabile
0,0 < 0,2	Relație foarte slabă, neglijabilă
0,2-0,4	Asociere slabă, scăzută
0,4-0,7	Asociere moderată
0,7-0,9	Asociere puternică
0,9 < 1,0	Relație foarte puternică
1,0	Asociere perfectă

Observație: Lambda poate lua valoarea 0 chiar dacă există o relație între cele două variabile. Acest fapt se datorează împrăstierii datelor, care sunt puternic condensate într-una dintre categoriile variabilei dependente.

Să urmărim, de exemplu, dacă există o asociere între repetarea cifrelor și memorarea acestora de către subiecți. Datele sunt prezentate în tabelul de mai jos.

Tabelul 8.6. Relația dintre repetarea cifrelor și memorarea acestora

		Repetarea cifrelor		Total
		Nu	Da	
Memorie cifre	rezultate slabe	16	7	23
	rezultate bune	24	32	56

Observăm că datele sunt puternic concentrate în categoria *rezultate bune* ale variabilei dependente *memorie cifre* (56 de subiecți, comparativ cu numai 23 în cealaltă categorie) indiferent de faptul că repetăm cifrele subiecților sau nu. Deschidem fișierul *memorie_cifre* și calculăm Lambda. Urmărim rezultatele care ne interesează în tabelele *Crosstabulation* și *Directional Measures*.

memorie cifre * repetare Crosstabulation

			repetare		Total
			nu	da	
memorie cifre	rezultate slabe	Count	16	7	23
		% within repetare	40,0%	17,9%	29,1%
		Adjusted Residual	2,2	-2,2	
	rezultate bune	Count	24	32	56
		% within repetare	60,0%	82,1%	70,9%
		Adjusted Residual	-2,2	2,2	
Total	Count	40	39	79	
	% within repetare	100,0%	100,0%	100,0%	

Directional Measures

			Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Nominal by Nominal	Lambda	Symmetric	,129	,113	1,077	,282
		memorie cifre Dependent	,000	,000		
		repetare Dependent	,205	,171	1,077	,282
	Goodman and Kruskal tau	memorie cifre Dependent	,059	,052		,032 ^d
		repetare Dependent	,059	,051		,032 ^d

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

c. Cannot be computed because the asymptotic standard error equals zero.

d. Based on chi-square approximation

Deși din tabelul *Crosstabulation* observăm că reziduurile standardizate ajustate depășesc intervalul $[-2, 2]$ – fapt ce ne face să credem că există o asociere între cele două variabile –, valoarea obținută pentru Lambda este 0,0. Acest rezultat este dat de

faptul că frecvențele sunt concentrate în nivelul *rezultate bune*, al variabilei dependente *memorie*. În această situație, avem două alternative (Argyrous, 2005): fie ne vom raporta la un alt indicator al asocierii, în cazul de față τ al lui Goodman și Kruskal, fie standardizăm valorile din tabel astfel încât valorile totale pe fiecare linie să fie egale. Pentru prima variantă, $\tau = 0,059$, $p = 0,032$, semnificativ statistic, ceea ce înseamnă că există o asociere între cele două variabile, în sensul că repetarea cifrelor conduce la o mai bună memorare a acestora.

Standardizarea frecvențelor din tabel pe linie presupune eliminarea variațiilor date de concentrarea frecvențelor într-una dintre liniile variabilei dependente. Vom standardiza totalul pe linii, astfel încât, pe fiecare linie, suma totală a frecvențelor să fie 100. Ulterior, când vom calcula și vom prezenta Lambda vom face următoarea specificație: „În calcularea valorii Lambda, frecvențele marginale pe fiecare linie au fost standardizate având suma 100”. Vom calcula procentul celor care au rezultate slabe și nu repetă cifre din totalul celor cu rezultate slabe (împărțim 16 la 23 și înmulțim cu 100) și vom repeta operația pentru fiecare dintre celelalte, obținând cifrele din tabelul de mai jos.

Tabelul 8.7. Relația dintre repetarea cifrelor și memorarea acestora (standardizarea tabelului astfel încât totalurile pe linii să fie egale)

		Repetarea cifrelor		Total
		Nu	Da	
Memorie cifre	rezultate slabe	$\frac{16}{23} \times 100 = 70\%$	$\frac{7}{23} \times 100 = 30\%$	100%
	rezultate bune	$\frac{24}{56} \times 100 = 43\%$	$\frac{32}{56} \times 100 = 57\%$	100%

În continuare vom folosi aceste procente *ca și cum* ar fi frecvențele reale. Deschidem baza de date *repetare_cifre_standardizat* și calculăm Lambda. Urmărind rezultatele din tabelul *Directional Measures* observăm că $\lambda = 0,270$, $p = 0,003$, ceea ce înseamnă că există o asociere slabă între repetarea cifrelor și memorarea acestora.

Directional Measures

			Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Nominal by Nominal	Lambda	Symmetric	,219	,084	2,397	,017
		memorie cifre Dependent	,270	,080	2,957	,003
		repetare Dependent	,161	,105	1,407	,159
	Goodman and Kruskal tau		,074	,037		,000 ^c
		repetare Dependent	,074	,037		,000 ^c

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

c. Based on chi-square approximation

8.3. Teste de asociere pentru variabile ordinale

Vom analiza în continuare asocierea a două variabile ordinale măsurate pe scale cu puține trepte sau asocierea dintre o variabilă ordinală și una măsurată pe scale de intervale sau proporții.

Există mai mulți indicatorii statistici pe care-i putem folosi :

- *Gamma* – pentru relații simetrice, în care nu avem motive să considerăm că una din variabile este independentă, iar cealaltă dependentă ;
- *d al lui Sommer* – pentru relații asimetrice, în care avem motive să considerăm că una din variabile este independentă, iar cealaltă dependentă ;
- *tau-b al lui Kendall*, pentru relații simetrice, fiind considerat varianta simetrică a indicatorului *d al lui Sommer* ;
- *tau-c al lui Kendall*, pentru relații simetrice, folosit pentru situația în care numărul de linii este diferit de numărul de coloane (tabele 3×4, de exemplu).

Coeficienții de asociere iau valori între -1 (semnificând asociere perfectă negativă între variabile) și +1 (semnificând asociere perfectă pozitivă), valoarea 0 fiind echivalentă cu absența asocierii între variabile.


8.3.1. Aplicarea testelor de asociere pentru variabile ordinale

Să presupunem că după predarea ecuației de gradul al doilea la șase clase de elevi diferite, omogene în ceea ce privește performanța la matematică, profesorul vrea să analizeze dacă numărul de exerciții-exemple efectuate la oră influențează rezultatele la un test dat la sfârșitul orei conținând ecuații de gradul al doilea. La două dintre clase rezolvă cu elevii la tablă trei ecuații ca exemplu, la alte două clase rezolvă șase ecuații, iar la clasele rămase nouă ecuații. Ulterior, toate clasele primesc același test, conținând ecuații de gradul al doilea, iar pe baza rezultatelor obținute, elevii sunt împărțiți în trei grupe : elevi cu performanțe slabe, cu performanțe medii și cu performanțe ridicate. Datele sunt prezentate în tabelul de mai jos.


Tabelul 8.8. Relația dintre numărul de exemple și performanța la test

		Numărul de exerciții-exemplu			Total
		trei	șase	nouă	
Performanțe test	slabe	<u>30</u>	15	10	55
		<u>60%</u>	33,3%	18,2%	
	medii	15	<u>20</u>	15	50
		30%	<u>44,4%</u>	27,3%	
	ridicate	5	10	<u>30</u>	45
		10%	22,2%	<u>54,5%</u>	
Total		50	45	55	150

Deschidem fișierul *exerciții*. Trecem variabila independentă, *exerciții*, pe coloane, iar variabila dependentă, *rezultate*, pe linii.



Activăm butonul *Statistics*, iar în fereastra corespunzătoare lui selectăm *Gamma* și *Sommers'd*; apoi clic *Continue*.



Activăm apoi butonul *Cells*, în câmpul *Residuals* bifăm *Adj. Standardized* și de asemenea, în câmpul *Percentages* bifăm opțiunea *Column* (deoarece VI este trecută pe coloane), apoi clic *Continue* și *OK*.

8.3.2. Interpretarea outputului

Interpretarea rezultatelor din tabelul *Crosstabulation* se face la fel ca în cazul testelor prezentate anterior. Observăm că dintre cei 50 de elevi care au lucrat la clasă doar trei exerciții, 30 (60%) au obținut performanțe scăzute, 15 (30%) performanțe medii și doar 5 (10%) performanțe ridicate. De asemenea, dintre cei 45 de subiecți care au lucrat șase exerciții, 15 (33,3%) au obținut performanțe scăzute, 20 (44,4%) performanțe medii și 10 (22,2%) performanțe ridicate. În schimb, dintre cei 55 de elevi care au lucrat nouă exerciții, 10 (18,2%) au obținut performanțe scăzute, 15 (27,3%) performanțe medii și 30 (54,5%) performanțe ridicate. Se constată astfel că odată cu creșterea numărului de exerciții lucrate, se amplifică și numărul elevilor care obțin performanțe ridicate.

performante test * numarul de exercitii Crosstabulation

			numarul de exercitii			Total
			trei exercitii- exemplu	sase exercitii- exemplu	noua exercitii- exemplu	
performante test	performante scazute	Count	30	15	10	55
		% within numarul de exercitii	60,0%	33,3%	18,2%	36,7%
		Adjusted Residual	4,2	-,6	-3,6	
	performante medii	Count	15	20	15	50
		% within numarul de exercitii	30,0%	44,4%	27,3%	33,3%
		Adjusted Residual	-,6	1,9	-1,2	
	performante ridicate	Count	5	10	30	45
		% within numarul de exercitii	10,0%	22,2%	54,5%	30,0%
		Adjusted Residual	-3,8	-1,4	5,0	
Total	Count	50	45	55	150	
	% within numarul de exercitii	100,0%	100,0%	100,0%	100,0%	

În tabelul *Directional Measures* este prezentat indicatorul statistic asimetric *d* al lui Sommer : $d = 0,401$, $p = 0,000$, iar în tabelul *Symetric Measures* indicatorul simetric Gamma = 0,571, $p = 0,000$. Așadar, există o asociere semnificativă pozitivă între variabilele analizate, creșterea numărului de exerciții lucrate conducând la performanțe ridicate în rândul elevilor.

Directional Measures

			Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Ordinal by Ordinal	Somers' d	Symmetric	,401	,065	6,195	,000
		performante test	,401	,065	6,195	,000
		numarul de exercitii	,401	,065	6,195	,000
		Dependent				

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

Symmetric Measures

		Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Ordinal by Ordinal	Gamma	,571	,082	6,195	,000
N of Valid Cases		150			

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

Capitolul 9. Teste neparametrice pentru compararea a două eșantioane independente

9.1. Testul Mann-Whitney U pentru două eșantioane independente

9.1.1. Prezentare generală

Scopul aplicării acestui test îl reprezintă compararea a două eșantioane independente atunci când : 1) VD este ordinală ; 2) VD este cantitativă, însă nu urmează o distribuție normală ; 3) eșantioanele sunt mici (de exemplu, 8-10 subiecți).

Condiții necesare pentru aplicarea testului Mann-Whitney U :

- a) grupele sunt independente – fiecare subiect face parte doar dintr-un singur grup, iar aceste grupe sunt independente ;
- b) variabila dependentă este cel puțin ordinală (putând fi măsurată pe scale de intervale sau proporții).

Exemple : 1) Verificăm dacă nivelul de empatie al profesorilor (variabilă ordinală, șase nivele) depinde de variabila gen. Variabila independentă este variabila *gen*, iar variabila dependentă este *empatie* ; 2) Verificăm dacă rezultatele la un test docimologic sunt influențate de familiarizarea cu tipul de itemi. Unei grupe de studenți i se dau exemple de asemenea itemi înainte cu două zile de test (grupul experimental), iar altei grupe de studenți nu i se comunică nimic despre tipul de itemi conținuți de test (grupul de control). Variabila independentă este *grup* (două categorii : experimental *versus* de control), iar variabila dependentă este *rezultate*.

9.1.2. Procedura de calcul a testului Mann-Whitney U

Să revenim asupra exemplului (2) de mai sus. Considerăm că rezultatele la test obținute de cele două grupe sunt următoarele :

Grup experimental :	10,	16,	19,	15,	17,	13,	9,	18
Grup de control :	6,	4,	12,	11,	5,	7,	8,	14

Fiind un test neparametric, testul Mann-Whitney are la bază compararea medianelor celor două grupe supuse comparației. Dacă grupul experimental ar avea o mediană mai

mare comparativ cu grupul de control, atunci ne așteptăm ca, în general, scorurile grupului experimental să fie mai mari comparativ cu scorurile grupului de control. Pentru a verifica dacă acest fapt este adevărat, vom trece în ordine crescătoare scorurile ambelor grupe, subliniind scorurile grupului experimental, astfel :

4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19.

Vom considera în continuare fiecare dintre cele 16 valori ca având un rang de la 1 la 16 (în ordine ierarhică, de la prima valoare – cea mai scăzută –, la ultima valoare – cea mai ridicată). Ulterior, vom aduna rangurile pentru grupul experimental, vom obține un scor total al rangurilor grupului experimental și vom calcula media rangurilor grupului experimental împărțind totalul rangurilor la numărul de scoruri aparținând grupului experimental. Vom face același lucru și pentru grupul de control.

$$S_1 = \text{suma totală a rangurilor}_{\text{gr. experimental}} = 6 + 7 + 10 + 12 + 13 + 14 + 15 + 16 = 93$$

$$S_2 = \text{suma totală a rangurilor}_{\text{gr. control}} = 1 + 2 + 3 + 4 + 5 + 8 + 9 + 11 = 43$$

$$\text{Media rangurilor}_{\text{gr. experimental}} = 93 / 8 = 11,625$$

$$\text{Media rangurilor}_{\text{gr. control}} = 43 / 8 = 5,375$$

Dacă medianele celor două grupe ar fi egale (conform ipotezei nule H_0), atunci mediile rangurilor celor două grupe ar trebui să fie aproximativ egale. Din valorile pe care le-am obținut se observă însă că media rangurilor pentru grupul experimental este mult mai mare comparativ cu media rangurilor pentru grupul de control.

În continuare se vor calcula statisticile Mann-Whitney U pentru fiecare dintre cele două grupe conform formulei $U = S - \frac{n(n+1)}{2}$, n fiind numărul de subiecți din grupul respectiv. O altă formulă de calcul pentru statistica U a unuia dintre grupuri este :

$$U_1 = n_1 n_2 + \frac{n_1(n_1 + 1)}{2} - S_1$$

Obținem, pentru grupul experimental, $U_{\text{gr. experimental}} = 93 - 36 = 57$.

Pentru grupul de control, $U_{\text{gr. control}} = 43 - 36 = 7$.

În continuare, în SPSS va fi luată în calcul statistica U cea mai mică, iar valoarea W Wilcoxon va fi suma rangurilor pentru grupul cu statistica U cea mai mică, în cazul de față pentru grupul de control. Vom observa în SPSS că vor fi raportate statisticile $U = 7$ și $W = 43$.

9.1.3. Aplicarea testului Mann-Whitney U

În exemplul de mai sus, verificăm dacă familiarizarea cu tipul de itemi ai unui test docimologic influențează rezultatele la test a celor două grupe de studenți. Variabila independentă este variabila *grup*, iar variabila dependentă este variabila *rezultate*. Deschi-deți fișierul *rezultate*. Călea în SPSS este: *Analyze* → *Nonparametric Tests* → *2 Independent Samples*.

Valori - SPSS Data Editor

File Edit View Data Transform Analyze Graphs Utilities Window Help

1: mediul

	mediul	gen
1	1	
2	1	
3	1	
4	1	
5	1	
6	1	
7	1	
8	1	
9	1	1
10	1	1
11	1	2
12	1	1
13	1	1
14	1	1

Reports

- Descriptive Statistics
- Compare Means
- General Linear Model
- Correlate
- Regression
- Loglinear
- Classify
- Data Reduction
- Scale
- Nonparametric Tests**
 - Chi-Square...
 - Binomial...
 - Runs...
 - 1-Sample K-S...
 - 2 Independent Samples...**
 - K Independent Samples...
 - 2 Related Samples...
 - K Related Samples...
- Survival
- Multiple Response

	imag	var
9	17	
3	13	
8	8	
2	19	
8	17	
8	3	
19	15	

Two-Independent-Samples Tests

Test Variable List:

rezultat

Grouping Variable:

grup(? ?)

Define Groups...

Test Type

☒ Mann-Whitney U

☐ Moses extreme reaction

Two Independent Samples: Defi...

Group 1: 1

Group 2: 2

Continue

Cancel

Help

Testul selectat automat de SPSS este *Mann-Whitney U*. Trecem variabila *rezultate* în câmpul *Test Variable List*, iar variabila *grup* în câmpul *Grouping variable*, activăm butonul *Define groups* și în caseta de dialog trecem valorile corespunzătoare nivelelor variabilei *grup* („1” și „2”), apoi clic *Continue* și *OK*. Vom discuta rezultatele obținute continuare.

9.1.4. Interpretarea outputului

Tabelul *Ranks* prezintă numărul subiecților, media rangurilor și suma rangurilor pentru fiecare grup. Observăm că aceste valori sunt egale cu cele calculate de noi mai sus. După cum știm deja, media rangurilor este obținută din împărțirea sumei rangurilor la numărul de subiecți ai grupului respectiv.

Ranks

	GRUP	N	Mean Rank	Sum of Ranks
REZULTAT	grup experimental	8	11,63	93,00
	grup de control	8	5,38	43,00
	Total	16		

Tabelul *Test Statistics* prezintă valorile testelor Mann-Whitney U, Wilcoxon W, transformarea valorii U în scor z și pragul de semnificație asociat. Din acest tabel ne interesează valoarea Z și pragul de semnificație p (sig.). Observăm că $z = -2,626$, $p = 0,007$, prin urmare există diferențe semnificative între cele două grupe în ceea ce privește rezultatele la testul docimologic.

Test Statistics^b

	REZULTAT
Mann-Whitney U	7,000
Wilcoxon W	43,000
Z	-2,626
Asymp. Sig. (2-tailed)	,009
Exact Sig. [2*(1-tailed Sig.)]	,007 ^a

a. Not corrected for ties.

b. Grouping Variable: GRUP

Deoarece din primul tabel știm că subiecții din grupul experimental au o medie a rangurilor superioară celor din grupul de control (11,63, comparativ cu 5,38) rezultă că studenții din grupul experimental obțin rezultate mai bune la test comparativ cu cei din grupul de control.

Indicatorul mărimii coeficientului r se calculează prin formula :


$$r = \sqrt{\frac{z^2}{n}} = \sqrt{\frac{2,626 \times 2,626}{16}} = \sqrt{\frac{6,90}{16}} = \sqrt{0,43} = 0,66$$

Obținem astfel o mărime a efectului $r = 0,66$, ceea ce conform criteriilor lui Cohen (1988) arată că efectul variabilei grup asupra variabilei rezultate este puternic ; altfel


spus, familiarizarea studenților cu tipul de itemi are un efect puternic asupra performanței acestora la testul docimologic.

În prezentarea rezultatelor vom calcula și prezenta mediana (mediana este mai potrivită decât media în cazul testelor neparametrice) pentru variabila *rezultate* în fiecare dintre cele două condiții ale variabilei *grup*.


Calea în SPSS este *Data* → *Split File*.




Selectăm *Organize output by groups*, iar în câmpul *Groups Based on* trecem variabila *mediu* și clic *OK*.



Deschidem apoi meniul *Analyze* → *Descriptive statistics* → *Frequencies*.



Trecem variabila *rezultate* în câmpul *Variable(s)*, apoi activăm butonul *Statistics*, iar aici selectăm *Median*, clic *Continue* și *OK*.



Rezultatele importante sunt prezentate mai jos :

Statistics^a

REZULTAT		
N	Valid	8
	Missing	0
Median		15,50

a. GRUP = grup experimental

Statistics^a

REZULTAT		
N	Valid	8
	Missing	0
Median		7,50

a. GRUP = grup de control

Am obținut pentru grupul experimental mediana $Mdn1 = 15,50$, iar pentru grupul de control mediana $Mdn2 = 7,50$.

9.1.5. Prezentarea rezultatelor

Pentru a verifica dacă rezultatele studenților la un test docimologic sunt influențate de familiarizarea cu tipul de itemi din test am aplicat testul U. Rezultatele arată că există diferențe semnificative între grupe ($U = 7$, $z = -2,626$, $p = 0,007$), studenții din grupul experimental (familiarizați cu tipul de itemi) obținând rezultate semnificativ mai mari


($Mdn = 15,50$) comparativ cu studenții din grupul de control ($Mdn = 7,50$). Mărimea efectului evidențiată de acest studiu este $r = 0,66$, ceea ce conform criteriilor lui Cohen (1988) ne arată că efectul variabilei grup asupra variabilei rezultate este puternic; altfel spus, familiarizarea studenților cu tipul de itemi are un efect puternic asupra performanței acestora la testul docimologic.

9.1.6. Observații

1. Testul U este echivalentul neparametric al testului t pentru eșantioane independente, însă este mai puțin puternic decât acesta din urmă.
2. Atenție: *pentru a decide în favoarea cărui grup diferențele sunt semnificative ne vom raporta la mediile rangurilor celor două grupe, și nu la sumele rangurilor.*

9.2. Alte teste neparametrice pentru două eșantioane independente

Deși cel mai frecvent test neparametric pentru două eșantioane independente este testul Mann-Whitney U, există și alte teste neparametrice pentru compararea a două eșantioane independente, în SPSS fiind disponibile următoarele: *Kolmogorov-Smirnov Z*, *Moses extreme reactions* și *Wald-Wolfowitz runs*.



- Testul *Kolmogorov-Smirnov z* este asemănător testului Mann-Whitney U. Se aplică dacă variabila dependentă are un număr redus de categorii, iar eșantioanele au volume mari (peste 40 fiecare), existând posibilitatea apariției unui număr ridicat de egalități de ranguri (Stan, 2000);

- *Moses extreme reactions* compară variabilitatea scorurilor în cele două grupuri, fiind oarecum varianta nonparametrică a testului Levene de verificare a omogenității varianțelor ;
- *Wald-Wolfowitz runs* este o altă variantă a testului U. În acest test, scorurile sunt ierarhizate și li se acordă ranguri la fel ca în cazul testului Mann-Whitney U, apoi considerate în ordinea crescătoare a rangurilor ; testul nu analizează însă rangurile, ci schimbările de scoruri din interiorul unui grup în ordinea rangurilor. Dacă nu ar fi diferențe între grupe, atunci rangurile din cele două grupe vor alterna aleatoriu. Dacă, în schimb, ar exista diferențe între grupe, atunci am observa mai multe ranguri dintr-un grup la capătul șirului cu ranguri mici și totodată mai multe ranguri din celălalt grup la capătul șirului cu ranguri mari.

Capitolul 10. Teste neparametrice pentru două eșantioane perechi

Vom discuta în continuare trei teste neparametrice pentru eșantioane perechi (sau variabile-pereche): 1) *testul Wilcoxon* pentru variabile ordinale sau cantitative (nefiind și normal distribuite); 2) *testul semnului* (Sign Test) pentru variabile ordinale cu un număr redus de categorii de răspuns (de exemplu, trei); 3) *testul McNemar* pentru variabile dihotomice.

Scopul acestor teste îl reprezintă compararea a două distribuții-pereche, compararea a două eșantioane perechi (test-retest sau variabile-pereche), în condițiile în care: 1) variabilele sunt dihotomice sau ordinale; 2) variabilele sunt cantitative, însă fie nu sunt normal distribuite, fie eșantioanele sunt de volum redus.

10.1. Testul Wilcoxon

10.1.1. Prezentare generală

Scopul aplicării testului Wilcoxon îl reprezintă compararea a două eșantioane sau variabile-pereche atunci când: 1) VD este ordinală; 2) VD este cantitativă (nefiind normal distribuită); 3) VD este cantitativă, iar eșantioanele sunt de volum redus.

Condiții: 1) eșantioanele sunt pereche (fiecare subiect este testat de două ori sau eșantioanele sunt corelate natural, de exemplu, părinți-copii); 2) VD este cantitativă sau ordinală cu mai multe categorii.

Exemple. 1) Verificăm dacă aplicarea unei metode noi de predare pe un lot de zece elevi conduce la performanțe superioare. Fiecare subiect este testat înainte și după aplicarea noii metodei (pretest-posttest), iar faptul că eșantioanele sunt mici ne obligă la aplicarea metodei neparametrice de comparare (deși VD este cantitativă); 2) Verificăm dacă există diferențe în ceea ce privește aprecierea a două produse diferite pe o scală de la 1 la 7 (de exemplu, două metode de evaluare sau două obiecte de studiu etc.); 3) Verificăm dacă există diferențe între copii și părinți în ceea ce privește importanța acordată valorii *autonomie* pe o scală de la 1 la 7.

10.1.2. Procedura de calcul a testului Wilcoxon

Să analizăm dacă aplicarea unei strategii de creștere a stimei de sine asupra unui grup de zece elevi a avut efect pozitiv sau nu. Pentru aceasta, măsurăm stima de sine a elevilor înainte și după aplicarea tehnicii respective. Datele sunt prezentate în tabelul următor.

Testul Wilcoxon calculează mai întâi diferența dintre scorurile celor două variabile pentru fiecare subiect (*după-înainte*), apoi stabilește semnul pentru fiecare dintre diferențe, iar în final ierarhizează diferențele în valoare absolută. Dacă anumite diferențe iau valoarea zero acestea vor fi ignorate pentru că nu oferă informații. Apoi sunt calculate suma rangurilor pentru diferențele negative, suma rangurilor pentru diferențele pozitive, media rangurilor pentru diferențele negative și media rangurilor pentru diferențele pozitive. În calcularea indicatorului statistic Wilcoxon vor fi folosite atât informații privind semnul diferențelor dintre fiecare pereche de valori, cât și magnitudinea acestor diferențe. Dacă nu ar exista diferențe între cele două condiții, atunci am obține un număr echivalent de diferențe pozitive și negative de aproximativ aceeași magnitudine, iar aceste diferențe ar tinde să se anuleze unele pe altele.

Tabelul 10.1. Scorurile subiecților la stimă de sine înainte și după intervenție, precum și calculele necesare pentru testul Wilcoxon

Stima de sine înainte de intervenție	Stimă de sine după intervenție	Diferența $V_2 - V_1$	$ V_2 - V_1 $	Rangul diferenței	Semnul diferenței
7	9	2	2	5,5	+
8	7	-1	1	2,5	-
5	7	2	2	5,5	+
6	10	4	4	8,5	+
6	7	1	1	2,5	+
5	4	-1	1	2,5	-
4	8	4	4	8,5	+
7	6	-1	1	2,5	-
6	9	3	3	7	+
5	10	5	5	10	+

În continuare va trebui să adunăm rangurile pentru cazurile în care diferențele erau negative și apoi rangurile pentru cazurile în care diferențele erau pozitive.

$$\text{Sumă ranguri}_{\text{negative}} = 2,5 + 2,5 + 2,5 = 7,5$$

$$\text{Sumă ranguri}_{\text{pozitive}} = 5,5 + 5,5 + 8,5 + 2,5 + 8,5 + 7 + 10 = 47,5$$

Calculăm acum media rangurilor negative și media rangurilor pozitive.

$$\text{Media rangurilor}_{\text{negative}} = 7,5/3 = 2,5$$

$$\text{Media rangurilor}_{\text{pozitive}} = 47,5/7 = 6,79$$

10.1.3. Aplicarea testului Wilcoxon

Să analizăm acum în SPSS exemplul de mai sus. Deschidem fișierul *stima_intervenție*. Calea de obținere în SPSS a rezultatelor la testul Wilcoxon este : *Analyze* → *Nonparametric Tests* → *2 Related Samples*.

Valori - SPSS Data Editor

File Edit View Data Transform **Analyze** Graphs Utilities Window Help

1 : mediul

	mediul	gen
1	1	
2	1	
3	1	
4	1	
5	1	
6	1	
7	1	
8	1	
9	1	1
10	1	1
11	1	2
12	1	1

Reports
Descriptive Statistics
Compare Means
General Linear Model
Correlate
Regression
Loglinear
Classify
Data Reduction
Scale
Nonparametric Tests
Survival
Multiple Response

Chi-Square...
Binomial...
Runs...
1-Sample K-S...
2 Independent Samples...
K Independent Samples...
2 Related Samples...
K Related Samples...

În câmpul *Test Type* ne asigurăm că este selectat testul *Wilcoxon*. Selectăm variabilele *înainte* și *după* și le trecem în câmpul *Test Pair(s) List* din partea dreaptă, apoi clic *OK*.

Two-Related-Samples Tests

înainte
după

Test Pair(s) List:
înainte - după

Current Selections
Variable 1:
Variable 2:

Test Type
☒ Wilcoxon ☐ Sign ☐ McNemar

Options...

OK
Paste
Reset
Cancel
Help

10.1.4. Interpretarea outputului

Tabelul *Ranks* prezintă media rangurilor, suma rangurilor și numărul de subiecți pentru fiecare dintre cele trei situații de comparare: ranguri negative (trei cazuri în care rangul variabilei *după* este mai mic decât rangul variabilei *înainte*, știm și din tabelul de mai sus), ranguri pozitive (șapte cazuri în care rangul variabilei *după* este mai mare decât rangul variabilei *înainte*) și situațiile de egalitate (cazuri în care valorile variabilelor *înainte* și *după* ar fi fost egale, iar în tabelul de mai sus ar fi apărut valoarea zero în cazul diferenței dintre valorile celor două variabile).

Ranks

		N	Mean Rank	Sum of Ranks
DUPA - INAINTE	Negative Ranks	3 ^a	2,50	7,50
	Positive Ranks	7 ^b	6,79	47,50
	Ties	0 ^c		
	Total	10		

a. DUPA < INAINTE

b. DUPA > INAINTE

c. INAINTE = DUPA

Tabelul *Test Statistics* prezintă rezultatele testului de comparare.

Cum $z = -2,055$, $p = 0,040$, rezultă că există diferențe semnificative între stima de sine măsurată înainte de intervenție și cea măsurată după intervenție.

Test Statistics^b

	DUPA - INAINTE
Z	-2,055 ^a
Asymp. Sig. (2-tailed)	,040

a. Based on negative ranks.

b. Wilcoxon Signed Ranks Test

Pentru a vedea sensul diferenței inspectăm valorile din coloana *Sum of Ranks* din primul tabel și ne vom raporta la suma de ranguri cea mai mare. În cazul nostru, valoarea cea mai ridicată este 47,5 și corespunde rangurilor pozitive, adică situațiilor în care rangurile variabilei *după* sunt mai mari decât rangurile variabilei *înainte* (după > înainte); prin urmare stima de sine a subiecților după intervenție este mai mare decât stima de sine a subiecților înainte de intervenție.

În final, va trebui să calculăm mărimea efectului (aplicând formula 4.14) și valorile mediane pentru fiecare dintre cele două variabile pereche.

$$r = \sqrt{\frac{z^2}{n}} = \sqrt{\frac{2,055 \times 2,055}{10}} = 0,65$$

10.1.5. Prezentarea rezultatelor

Pentru a verifica dacă stima de sine a subiecților este mai mare după intervenție comparativ cu situația anterioară intervenției am aplicat testul Wilcoxon. Rezultatele obținute indică faptul că intervenția experimentală a avut un efect semnificativ existând diferențe semnificative între variabilele *înainte* și *după*, $z = -2,055$, $p = 0,040$, stima de sine a subiecților fiind mai ridicată după intervenție ($Mdn = 7,5$) comparativ cu situația anterioară intervenției ($Mdn = 6$). Mărimea acestui efect este $r = 0,65$, ceea ce evidențiază un efect puternic al intervenției experimentale asupra creșterii stimei de sine a subiecților.

Observație. Testul Wilcoxon ia în calcul atât sensul diferențelor, cât și amplitudinea lor.

10.2. Testul semnelui (Sign Test)

10.2.1. Prezentare generală

Scopul aplicării testului semnelui îl reprezintă compararea a două eșantioane perechi (sau variabile-pereche) atunci când studiem sensul diferenței dintre ele fără a lua în calcul și amplitudinea acestora (comparăm doar numărul diferențelor pozitive cu numărul diferențelor negative).


Condiții: 1) eșantioanele sunt perechi; 2) VD este cantitativă sau ordinală (de regulă, cu puține categorii).

Exemple. 1) Verificăm dacă efectele unei intervenții educaționale privind ameliorarea aptitudinilor de comunicare la elevi sunt mai degrabă pozitive decât negative. Vom compara numărul efectelor pozitive (progres) cu numărul efectelor negative (regres). 2) Verificăm dacă aprecierile copiilor sunt mai pozitive comparativ cu cele ale părinților în ceea ce privește valoarea *libertate*.

Testul semnelui calculează diferența dintre cele două variabile pentru toate cazurile și le clasifică drept pozitive sau negative; dacă cele două variabile ar avea distribuții similare, atunci numărul de semne pozitive nu ar diferi semnificativ de numărul de semne negative.

10.2.2. Aplicarea testului semnelui

Studiem eficiența unei metode de dinamică de grup privind integrarea elevilor în cadrul grupului. VD este *poziția în cadrul grupului* cu trei nivele: poziție marginală, medie și centrală, iar VI este *momentul testării* cu două nivelele: înainte și după intervenție. Deschideți fișierul *Integrare_grup*. Calea în SPSS este: *Analyze* → *Nonparametric Tests* → *2 Related Samples*; în câmpul *Test Type* deselectăm testul Wilcoxon și bifăm testul semnelui (*Sign*), trecem variabilele *pretest* și *posttest* în câmpul *Test Pair(s) List* din partea dreaptă, apoi clic *OK*.



10.2.3. Interpretarea outputului

Tabelul *Frequencies* prezintă numărul diferențelor negative (1), a celor pozitive (9) și a egalităților (20).

Frequencies

		N
pozitia in cadrul grupului dupa interventie - pozitia in cadrul grupului inainte de interventie	Negative Differences ^a	1
	Positive Differences ^b	9
	Ties ^c	20
	Total	30

- pozitia in cadrul grupului dupa interventie < pozitia in cadrul grupului inainte de interventie
- pozitia in cadrul grupului dupa interventie > pozitia in cadrul grupului inainte de interventie
- pozitia in cadrul grupului inainte de interventie = pozitia in cadrul grupului dupa interventie

Tabelul *Test Statistics* prezintă doar pragul de semnificație $p = 0,021$ privind comparația diferențelor pozitive cu cele negative, prin urmare există o diferență semnificativă în sensul că sunt mai multe schimbări pozitive¹ în urma intervenției, așadar intervenția a fost eficientă.

1. Deoarece numărul diferențelor pozitive (9) este mai mare decât al celor negative (1), iar SPSS a făcut diferența dintre posttest și pretest.

Test Statistics^b

	pozitia in cadrul grupului dupa interventie - pozitia in cadrul grupului inainte de interventie
Exact Sig. (2-tailed)	,021 ^a

a. Binomial distribution used.

b. Sign Test

Observație. Deoarece testul semnului nu ia în calcul și amplitudinea diferențelor are o putere mai slabă statistic comparativ cu testul Wilcoxon. Dacă am aplica testul semnului pentru exemplul discutat la testul Wilcoxon am obține că strategia de creștere a stimei de sine nu a avut efecte semnificative ($p = 0,344$), deși testul Wilcoxon a evidențiat efecte semnificative.

10.3. Testul McNemar

10.3.1. Prezentare generală

Scopul aplicării testului McNemar îl reprezintă compararea a două eșantioane sau variabile-pereche pentru variabile dihotomice.

Testul McNemar este definit de un tabel 2×2 de forma :

$$y = \begin{matrix} y_{11} & y_{12} \\ y_{21} & y_{22} \end{matrix}$$


Condiții : 1) eșantioanele sunt perechi ; 2) VD este dihotomică.

Exemple. 1) Verificăm dacă există o schimbare în preferința profesorilor pentru o metodă nouă de predare înainte și după o sesiune de informare privind respectiva metodă. VD este preferința (da/nu), iar VI este momentul (înainte/după informare). 2) Verificăm dacă există o legătură între succesul/eșecul elevilor la un examen de capacitate și alocarea de ore pentru studiu independent în weekend. VI este alocarea de ore pentru studiu independent (da/nu), iar VD este rezultatul la examenul de capacitate (succes/eșec).

10.3.2. Aplicarea testului McNemar

Să analizăm dacă desfășurarea unei campanii publicitare protalent a avut efect asupra schimbării atitudinii membrilor consiliului județean față de prioritatea unor programe destinate susținerii talentelor în societatea actuală. VI este *momentul temporal* (înainte/ după campanie), iar VD este *prioritate talent* (da/nu).

Deschidem fișierul *Prioritate_talent*. Calea în SPSS este : *Analyze* → *Nonparametric Tests* → *2 Related Samples* ; în câmpul *Test Type* deselectăm testul Wilcoxon și bifăm testul McNemar, trecem variabilele *înainte* și *după* în câmpul *Test Pair(s) List* din partea dreaptă și clic *OK*.



10.3.3. Interpretarea outputului

Primul tabel prezintă frecvențele observate înainte și după campanie într-un tabel 2×2 .

**prioritatea sustinerii talentelor - înainte de campanie
& prioritatea sustinerii talentelor - după campanie**

prioritatea sustinerii talentelor - înainte de campanie	prioritatea sustinerii talentelor - după campanie	
	0	1
0	6	10
1	0	14

În tabelul *Test Statistics* observăm că $p = 0,000$, prin urmare există diferențe semnificative între grupuri (momentele testării), iar direcția diferenței este dată de semnul valorii testului McNemar (Mehta și Patel, 1996).

Test Statistics^b

	prioritatea sustinerii talentelor - inainte de campanie & prioritatea sustinerii talentelor - dupa campanie
N	30
Exact Sig. (2-tailed)	,002 ^a

a. Binomial distribution used.

b. McNemar Test

Valoarea testului McNemar este calculată făcând diferența pe diagonala secundară :

$$MC(y) = y_{12} - y_{21} = 10 - 0 = +10$$

Cum rezultatul are semnul pozitiv rezultă că efectul campaniei este pozitiv, în urma acestuia subiecții tinzând să-și modifice atitudinea în sensul susținerii talentelor.

Observații :

1. Testul McNemar compară schimbările de la un grup la altul, perechile discordante (valorile pe diagonala secundară, y_{12} și y_{21}). În aplicația de mai sus, din cele zece perechi discordante ($10 + 0$), sunt mai multe schimbări de la 0 la 1 ($y_{12} = 10$) decât de la 1 la 0 ($y_{21} = 0$).
2. O altă cale de obținere a testului McNemar este *Analyze → Descriptive Statistics → Crosstabs*. Trecem variabila *înainte* pe linie și variabila *după* pe coloană, activăm butonul *Statistic*, iar în caseta de dialog rezultată bifăm testul McNemar.

Capitolul 11. Teste neparametrice pentru mai mult de două eșantioane independente

Testele discutate în această secțiune sunt de două tipuri : cele folosite atunci când ipoteza de cercetare H_1 presupune că populațiile din care au fost extrase eșantioanele sunt neordonate și cele folosite în cazul atunci când de cercetare H_1 presupune că populațiile din care au fost extrase eșantioanele sunt ordonate (Mehta și Patel, 1996). Pentru situația în care H_1 presupune populații neordonate folosim testul Kruskal-Wallis și testul mediane, iar pentru situația în care H_1 presupune populații ordonate folosim testul Jonckheere-Terpstra.

Ipoteza H_1 referitoare la populații neordonate presupune că nu există o ordonare a priori a celor k populații din care au fost extrase eșantioanele, iar cele k populații sunt diferite. Un exemplu ar fi cazul în care cele k populații pot reprezenta etnii sau religii diferite etc. Eșantioanele sunt extrase din asemenea populații urmând a fi măsurate anumite caracteristici (venit, implicare în sarcină etc.). Nu există argumente a priori pentru care populațiile (de exemplu, religiile) să fie ordonate crescător sau descrescător în funcție de venitul sau implicarea în sarcină a acestora. Ceea ce putem susține în H_1 este doar că populațiile sunt diferite în ceea ce privește venitul sau angajarea în sarcină. Prin urmare, ipotezele testate în asemenea situații sunt bidirecționale. În asemenea demersuri folosim, de obicei, testul Kruskal-Wallis.

Ipoteza H_1 referitoare la populații ordonate presupune că există o ordonare crescătoare sau descrescătoare a priori a celor k populații din care au fost extrase eșantioanele. De exemplu, cele k populații pot reprezenta k nivele progresive de creștere a cantității de alcool consumat, iar VD ar putea fi numărul de accidente la volan. Ipoteza nulă H_0 va fi că diferitele nivele de consum de alcool consumat conduc la un număr de accidente aproximativ egal. H_1 ar putea fi în acest caz că există o legătură între consumul de alcool și accidente în sensul că o creștere a nivelului de alcool consumat conduce la o creștere a numărului de accidente. Desigur, ordonarea poate fi ascendentă sau descendentă, iar relația dintre VI și VD poate fi directă sau inversă. Avantajul unor astfel de ipoteze este că ele sunt unidirecționale și ca atare testele folosite sunt mai puternice comparativ cu cele folosite pentru populații neordonate. Testul folosit în asemenea demersuri este testul Jonckheere-Terpstra.

11.1. Testul Kruskal-Wallis H

11.1.1. Prezentare generală

Acest test este echivalentul neparametric al testului ANOVA one-way.

Testul Kruskal-Wallis H urmărește compararea mai multor eșantioane independente atunci când : 1) VD este cantitativă, dar nu urmează o distribuție normală ; 2) VD este ordinală ; 3) VD este cantitativă, însă eșantioanele sunt de volume mici.

Condiții : eșantioanele sunt independente, iar VD este cantitativă sau ordinală.

Exemple. 1) Verificăm dacă există diferențe semnificative în funcție de gradul didactic al profesorilor în ceea ce privește nivelul de empatie emoțională. VI este *grad* (cu trei categorii : definitivat, gradul 2 și gradul 1), iar VD este *empatie* (variabilă ordinală, existând șase nivele de empatie). 2) Verificăm dacă există diferențe semnificative în funcție de religie în ceea ce privește atitudinea față de eutanasiere. VI este *religie* (trei categorii : ortodox, catolic, protestant), VD este eutanasierea (cantitativă), iar eșantioanele sunt de volume mici și profund inegale (de exemplu, eșantionul de protestanți conține doar șapte subiecți).

Asemenea testului Mann-Whitney, și testul Kruskal-Wallis H are la bază analiza rangurilor, ierarhizarea datelor. Scorurile sunt ierarhizate de la cel mai mic la cel mai mare, ignorând grupurile din care fac parte, se calculează apoi suma rangurilor pentru fiecare dintre grupuri, iar pe baza acestor sume de ranguri se obține rezultatul la testul H pe baza formulei :

$$H = \frac{12}{N(N+1)} \sum_{i=1}^k \frac{R_i^2}{n_i} - 3(N+1)$$

unde N este totalul subiecților, R_i reprezintă suma rangurilor pentru grupul i , iar n_i reprezintă numărul de subiecți din grupul i .

11.1.2. Aplicarea testului Kruskal-Wallis H

Vom analiza dacă patru metode diferite de predare conduc la rezultate diferite în ceea ce privește performanța elevilor. Deschidem fișierul *Metode_predare*. Calea în SPSS este : *Analyze* → *Nonparametric Tests* → *K Independent Samples*.

Metode_predare - SPSS Data Editor

File Edit View Data Transform Analyze Graphs Utilities Window Help

1: metode

	metode	performa
1	1	8,1
2	1	8,6
3	1	8,7
4	1	9,3
5	1	9,4
6	1	9,6
7	1	9,7
8	1	9,1
9	1	8,76
10	1	8,00
11	2	9,05
12	2	9,70

Analyze > Nonparametric Tests > K Independent Samples...

Trecem variabila *performanta* în câmpul *Test Variable List*, iar variabila *metode* în câmpul *Grouping Variable*, apoi clic pe butonul *Define Range* unde trecem 1 și 4 (valorile minime și maxime luate de categoriile VI) și clic *Continue*. Ne asigurăm că în câmpul *Test Type* este bifat testul *Kruskal Wallis H*, apoi clic *OK*.

Tests for Several Independent Samples

Test Variable List:
performanta [perform]

Grouping Variable:
metode[? ?]

Define Range...

Test Type
☒ Kruskal-Wallis H ☐ Median

Several Independent Samples: Define ...

Range for Grouping Variable
Minimum: 1
Maximum: 4

11.1.3. Interpretarea outputului

În tabelul *Ranks* sunt prezentate mediile de rang și numărul subiecților pentru fiecare dintre grupe. Observăm că în cazul aplicării metodei II media rangurilor este cea mai ridicată (27,45), urmând apoi metoda I (cu o medie a rangurilor de 24,75), apoi metoda III (cu o medie a rangurilor de 17,35) și în final, având eficiența cea mai redusă, metoda IV (cu o medie a rangurilor de 12,45).

Ranks

	metode predare	N	Mean Rank
performanta	metoda I	10	24,75
	metoda II	10	27,45
	metoda III	10	17,35
	metoda IV	10	12,45
	Total	40	

Tabelul *Test Statistics* prezintă valoarea testului Kruskal Wallis H (χ^2), gradele de libertate (df) și pragul de semnificație (Sig.). Cum $H(3) = 10,348$ și $p = 0,016$, rezultă că există diferențe semnificative în funcție de metodele de predare în ceea ce privește performanța elevilor.

Test Statistics^{a,b}

	performanta
Chi-Square	10,348
df	3
Asymp. Sig.	,016

a. Kruskal Wallis Test

b. Grouping Variable: metode predare

Totuși testul nu ne spune și între care metode diferențele sunt semnificative. De exemplu, inspectând mediile de rang din primul tabel observăm că grupele cărora li s-au aplicat metodele II și IV diferă semnificativ în ceea ce privește performanțele obținute de elevi ($MR_{II} = 27,45$, iar $MR_{IV} = 12,45$), deoarece sunt grupele cu mediile de rang maxim și minim, însă ar putea de asemenea exista diferențe și între grupele cărora li s-au aplicat metodele I și IV.

Pentru a ști între care dintre cele patru grupuri există diferențe semnificative va trebui să le comparăm două câte două aplicând testul Mann-Whitney U și să ajustăm pragul de semnificație în funcție de numărul de comparații (șase în cazul nostru), astfel că $\alpha = 0,05/6 = 0,008$.

Un alt neajuns al testului H este acela că nu poate fi calculat direct un indicator al mărimii efectului, acesta trebuind calculat și prezentat doar pentru fiecare comparație simplă în care aplicăm testul U (chiar dacă rezultatele sunt nesemnificative statistic).

Vom aplica în continuare testul Mann-Whitney U pentru fiecare dintre cele șase comparații pereche.

Metoda I vs. metoda II - Test Statistics^b

	performanta
Mann-Whitney U	47,000
Wilcoxon W	102,000
Z	-,227
Asymp. Sig. (2-tailed)	,820
Exact Sig. [2*(1-tailed Sig.)]	,853 ^a

a. Not corrected for ties.

b. Grouping Variable: metode preparare

Metoda I vs. metoda III - Test Statistics^b

	performanta
Mann-Whitney U	33,000
Wilcoxon W	88,000
Z	-1,288
Asymp. Sig. (2-tailed)	,198
Exact Sig. [2*(1-tailed Sig.)]	,218 ^a

a. Not corrected for ties.

b. Grouping Variable: metode preparare

Metoda I vs. metoda IV - Test Statistics^b

	performanta
Mann-Whitney U	21,500
Wilcoxon W	76,500
Z	-2,158
Asymp. Sig. (2-tailed)	,031
Exact Sig. [2*(1-tailed Sig.)]	,029 ^a

a. Not corrected for ties.

b. Grouping Variable: metode preparare

Metoda II vs. metoda III - Test Statistics^b

	performanta
Mann-Whitney U	19,000
Wilcoxon W	74,000
Z	-2,352
Asymp. Sig. (2-tailed)	,019
Exact Sig. [2*(1-tailed Sig.)]	,019 ^a

a. Not corrected for ties.

b. Grouping Variable: metode preparare

Metoda II vs. metoda IV - Test Statistics^b

	performanta
Mann-Whitney U	14,500
Wilcoxon W	69,500
Z	-2,691
Asymp. Sig. (2-tailed)	,007
Exact Sig. [2*(1-tailed Sig.)]	,005 ^a

a. Not corrected for ties.

b. Grouping Variable: metode preparare

Metoda III vs. metoda IV - Test Statistics^b

	performanta
Mann-Whitney U	33,500
Wilcoxon W	88,500
Z	-1,253
Asymp. Sig. (2-tailed)	,210
Exact Sig. [2*(1-tailed Sig.)]	,218 ^a

a. Not corrected for ties.

b. Grouping Variable: metode preparare



Prezentăm în continuare rezultatele obținute (inclusiv mărimea efectului r), raportându-le la pragul de semnificație corectat în funcție de numărul de comparații: $\alpha = 0,008$.

- Nu există diferențe semnificative între metoda I și metoda II în ceea ce privește efectele asupra performanței ($U = 47$, $z = -0,227$, $p = 0,820$, $r = 0,05$).
- Nu există diferențe semnificative între metoda I și metoda III în ceea ce privește efectele asupra performanței ($U = 33$, $z = -1,288$, $p = 0,198$, $r = 0,29$).
- Nu există diferențe semnificative între metoda I și metoda IV în ceea ce privește efectele asupra performanței ($U = 21,5$, $z = -2,158$, $p = 0,031$, $r = 0,48$) (atenție,

nu ne-am mai raportat la pragul clasic de semnificație 0,05, ci la cel ajustat prin metoda Bonferroni în funcție de numărul total de comparații simple, în cazul de față 0,008).

- Nu există diferențe semnificative între metoda II și metoda III în ceea ce privește efectele asupra performanței ($U = 19$, $z = -2,352$, $p = 0,019$, $r = 0,52$).
- Există diferențe semnificative între metoda II și metoda IV în ceea ce privește efectele asupra performanței ($U = 14,5$, $z = -2,691$, $p = 0,007$, $r = 0,60$).
- Nu există diferențe semnificative între metoda III și metoda IV în ceea ce privește efectele asupra performanței ($U = 33,5$, $z = -1,253$, $p = 0,210$, $r = 0,28$).

Va trebui să calculăm și mediana variabilei *performanță* pentru fiecare dintre cele patru grupuri. Vom aplica mai întâi procedura *Split File*. Calea în SPSS este *Data* → *Split File*, vom bifa opțiunea *Organize output by groups* și vom trece variabila *metode* în câmpul *Groups Based on* :, apoi clic *Ok*. În continuare vom calcula medianele prin procedura *Analyze* → *Descriptive Statistics* → *Frequencies*.



Current Status: Analysis by groups is off.

Tabelele cu medianele obținute în SPSS vor arăta astfel :

Statistics^a

performanta		
N	Valid	10
	Missing	0
Median		9,0500

a. metode predare = metoda I

Statistics^a

performanta		
N	Valid	10
	Missing	0
Median		9,0500

a. metode predare = metoda II

Statistics^a

performanta		
N	Valid	10
	Missing	0
Median		8,6600

a. metode predare = metoda III

Statistics^a

performanta		
N	Valid	10
	Missing	0
Median		8,5300

a. metode predare = metoda IV

Medianele la variabila *performanță* pentru fiecare dintre cele patru grupe sunt următoarele : $Mdn_{metoda I} = 9,05$, $Mdn_{metoda II} = 9,05$, $Mdn_{metoda III} = 8,66$ și $Mdn_{metoda IV} = 8,53$.

11.1.4. Prezentarea rezultatelor

Pentru a verifica dacă patru noi metode de predare conduc la performanțe diferite în rândul elevilor am aplicat testul Kruskal-Wallis H. Conform rezultatelor statistice obținute, performanța elevilor diferă semnificativ în funcție de metoda de predare adoptată [$H(3) = 10,348$, $p < 0,05$]. Pentru explorarea acestor diferențe am aplicat testul Mann-Whitney U, comparând metodele de predare două câte două. Datorită comparațiilor multiple realizate, pragul de semnificație a fost corectat prin metoda Bonferroni astfel că toate rezultatele au fost raportate la pragul de semnificație ajustat $\alpha = 0,008$. Rezultatele arată că performanța elevilor nu este diferită atunci când aplicăm metodele I *versus* II ($U = 47$, $z = -0,227$, $p = 0,820$, $r = 0,05$, $Mdn_I = 9,05$, $Mdn_{II} = 9,05$), metodele I *versus* III ($U = 33$, $z = -1,288$, $p = 0,198$, $r = 0,29$, $Mdn_I = 9,05$, $Mdn_{III} = 8,66$), metodele I *versus* IV ($U = 21,5$, $z = -2,158$, $p = 0,031$, $r = 0,48$, $Mdn_I = 9,05$, $Mdn_{IV} = 8,53$), metodele II *versus* III ($U = 19$, $z = -2,352$, $p = 0,019$, $r = 0,52$, $Mdn_{II} = 9,05$, $Mdn_{III} = 8,66$) sau metodele III *versus* IV ($U = 33,5$, $z = -1,253$, $p = 0,210$, $r = 0,28$, $Mdn_{III} = 8,66$, $Mdn_{IV} = 8,53$). Totuși, atunci când vom aplica metoda II de predare, performanța elevilor va fi semnificativ mai mare comparativ cu situația în care vom aplica metoda IV ($U = 14,5$, $z = -2,691$, $p = 0,007$, $r = 0,60$, $Mdn_I = 9,05$, $Mdn_{IV} = 8,53$).

Observație. La fel ca în cazul echivalentului parametric ANOVA One-Way, și rezultatul la testul Kruskal-Wallis poate să indice că nu există diferențe între grupuri, deși comparațiile

analitice două câte două prin testul Mann-Whitney pot conduce la descoperirea unor diferențe semnificative între grupuri.

11.2. Testul Jonckheere-Terpstra J

11.2.1. Prezentare generală

Testul Jonckheere-Terpstra J este echivalentul testului ANOVA one-way pentru analize direcționale. Procedura de calcul a acestui test este asemănătoare cu cea de la testul Kruskal-Wallis H, cu specificarea că, în cazul de față, se iau în calcul și informații privind ordinea grupelor. Deoarece vizează testarea unor ipoteze de cercetare unidirecționale, vom putea verifica dacă, de exemplu, o creștere a numărului de ore alocate învățării pentru un examen conduce la o creștere a performanței obținute de studenți la examen. Cum ordonarea nivelelor variabilei independente poate fi ascendentă sau descendentă, relația dintre variabila independentă și variabila dependentă poate fi directă sau inversă.

Deoarece ipoteza de cercetare este unidirecțională rezultă că testul Jonckheere-Terpstra J este mai puternic decât testul Kruskal-Wallis H sau testul medianei.

Trebuie să fim atenți la stabilirea nivelelor variabilei independente, deoarece acestea vor trebui să fie în ordine crescătoare sau descrescătoare. Dacă, de exemplu, VI are trei nivele (de exemplu, 0 ore de training, două ore de training și trei ore de training), atunci codificarea acestor nivele va fi de genul: 1 = „0 ore”, 2 = „două ore” și 3 = „trei ore” (sau în ordine inversă). Dacă, de exemplu, am codifica nivelele VI astfel: 1 = „două ore”, 2 = „0 ore” și 3 = „trei ore”, atunci nivelele nu mai sunt ordonate și rezultatele la testul Jonckheere-Terpstra J vor fi eronate. Acest test verifică dacă medianele grupurilor sunt ordonate crescător sau descrescător în funcție de ordinea specificată în codificarea nivelelor variabilei independente.

Testul Jonckheere-Terpstra J urmărește verificarea relației dintre ordonarea crescătoare sau descrescătoare a mai multor eșantioane independente și răspunsurile la VD atunci când: 1) VD este cantitativă, dar nu urmează o distribuție normală; 2) VD este ordinală; 3) VD este cantitativă, însă eșantioanele sunt de volume mici.


Condiții: eșantioanele sunt independente și ordonate, iar VD este cantitativă sau ordinală.

Exemple. 1) Verificăm dacă scăderea interacțiunii părinți-copii crește probabilitatea consumului de droguri la adolescenți. VI este numărul de interacțiuni zilnice (mai mult de 5, între 2 și 4, una sau niciuna), iar VD este numărul de ingerări de droguri pe săptămână; 2) Verificăm dacă avansarea în vârstă conduce la o creștere a probabilității de manifestare a unor comportamente religioase. VI este categoria de vârstă (20-29, 30-39, 40-49, 50-59, mai mult de 60 ani), iar VD este manifestarea de comportamente religioase.

11.2.2. Aplicarea testului Jonckheere-Terpstra J

Să analizăm dacă o creștere a numărului de ore de training (3 ore, 6 ore, 9 ore) conduce la o creștere a performanței. Deoarece eșantioanele sunt mici (zece subiecți) folosim o metodă neparametrică. Deschidem fișierul *Training*.

Calea în SPSS este: *Analyze* → *Nonparametric Tests* → *K Independent Samples*. Trecem variabila *performanță* în câmpul *Test Variable List*, iar variabila *training* în câmpul *Grouping Variable*, apoi clic pe butonul *Define Range* unde trecem 1 și 3 (valorile minime și maxime luate de categoriile VI), apoi clic *Continue*. Ne asigurăm că în câmpul *Test Type* este bifat testul *Jonckheere-Terpstra*, apoi clic *OK*.



11.2.3. Interpretarea outputului

Din tabelul *Jonckheere-Terpstra Test* observăm că valoarea testului J-T (numit și „J”) este $J = 201,50$, iar valoarea standardizată a testului J este $z = 1,960$, $p = 0,05$. Semnul pozitiv al testului z indică o relație directă între creșterea orelor de training și performanță (un trend ascendent al medianelor VD odată cu trecerea de la o treaptă a VI la o alta superioară).

Mărimea efectului calculată prin formula 4.14 este $r = \frac{\sqrt{z^2}}{n} = \frac{1,960}{\sqrt{30}} = 0,36$, ceea ce conform lui Cohen (1988) reprezintă un efect de nivel mediu. Astfel, putem afirma că o creștere a orelor de training are un efect de nivel mediu asupra performanței subiecților.

Jonckheere-Terpstra Test^a

	performata
Number of Levels in ore de training	3
N	30
Observed J-T Statistic	201,500
Mean J-T Statistic	150,000
Std. Deviation of J-T Statistic	26,273
Std. J-T Statistic	1,960
Asymp. Sig. (2-tailed)	,050

a. Grouping Variable: ore de training

Totuși, deoarece mărimea efectului discutată mai sus analizează un efect general, de cele mai multe ori este mai interesant să cunoaștem mărimea efectului pentru comparațiile-pereche. Sugerăm prin urmare aplicarea testului Mann-Whitney pentru analizarea comparațiilor-pereche și calcularea mărimii efectului pentru rezultatele la testul Mann-Whitney. Vom obține următoarele rezultate :

3 ore versus 6 ore training - Test Statistics^b

	performata
Mann-Whitney U	36,500
Wilcoxon W	91,500
Z	-1,022
Asymp. Sig. (2-tailed)	,307
Exact Sig. [2*(1-tailed Sig.)]	,315 ^a

a. Not corrected for ties.

b. Grouping Variable: ore de training

3 ore versus 9 ore training - Test Statistics^b

	performata
Mann-Whitney U	26,000
Wilcoxon W	81,000
Z	-1,818
Asymp. Sig. (2-tailed)	,069
Exact Sig. [2*(1-tailed Sig.)]	,075 ^a

a. Not corrected for ties.

b. Grouping Variable: ore de training

Pentru prima comparație, condiția de 3 ore *versus* condiția de 6 ore de training, am obținut $z = 1,022$, iar mărimea efectului va fi: $r_{3ore-6ore} = \frac{1,022}{\sqrt{20}} = 0,23$. Prin urmare, creșterea numărului de ore de training de la 3 la 6 are un efect slab asupra performanței subiecților.

Pentru a doua comparație, condiția de 3 ore *versus* condiția de 9 ore, am obținut $z = 1,818$, iar mărimea efectului este $r_{3ore-9ore} = \frac{1,818}{\sqrt{20}} = 0,41$, ceea ce înseamnă că o creștere a numărului de ore de training de la 3 la 9 are un efect mediu asupra creșterii performanței subiecților.

Vom calcula de asemenea și medianele la variabila performanță pentru fiecare dintre cele trei nivele de training folosind mai întâi procedura *Split File*. Obținem astfel că după 3 ore de training mediana este $Mdn = 8,66$, după 6 ore de training mediana este $Mdn = 8,91$, iar după 9 ore de training mediana este $Mdn = 9,05$.

Statistics^a

performata		
N	Valid	10
	Missing	0
Median		8,6600

a. ore de training = 3 ore

Statistics^a

performata		
N	Valid	10
	Missing	0
Median		8,9150

a. ore de training = 6 ore

Statistics^a

performata		
N	Valid	10
	Missing	0
Median		9,0500

a. ore de training = 9 ore

11.2.4. Prezentarea rezultatelor

Pentru a analiza efectul creșterii orelor de training asupra performanței subiecților am aplicat testul Jonckheere-Terpstra J. Rezultatele arată că există un trend ascendent semnificativ al performanței; cu cât crește numărul de ore alocate trainingului, cu atât crește mediana variabilei performanță, $J = 201,5$, $z = 1,960$, $p = 0,05$, $r = 0,36$.

Aplicând testul Mann-Whitney U pentru comparații simple am obținut că:

- există un efect slab al creșterii orelor de training de la 3 la 6 asupra performanței, $z = 1,022$, $r = 0,23$, $Mdn_{3 \text{ ore}} = 8,66$, $Mdn_{6 \text{ ore}} = 8,92$;
- există un efect mediu al creșterii orelor de training de la 3 la 9 asupra performanței, $z = 1,818$, $r = 0,41$, $Mdn_{3 \text{ ore}} = 8,66$, $Mdn_{9 \text{ ore}} = 9,05$.

11.3. Observații finale

1. Un semn negativ al valorii z pentru testul Jonckheere-Terpstra J indică un trend descendent al medianelor.

2. Testul J este mai puternic decât testul Kruskal-Wallis H. Putem verifica acest lucru aplicând testul H în cazul aplicației de mai sus; vom observa că rezultatele la testul H sunt nesemnificative.

3. Testul J este specific ipotezelor unidirecționale.

4. Deși ne-am putea gândi că aplicarea testului J este redundantă cu calcularea coeficientului de corelație neparametrică Spearman, totuși calitatea testului J se relevă în cazul în care anumite categorii ale VI conțin chiar și un singur subiect, caz în care testul J poate fi aplicat, iar corelația Spearman nu.

5. Ori de câte ori analizăm comparații între mai mult de două grupuri, va trebui să calculăm și rezultatele la testele Mann-Whitney de comparare două câte două a grupelor

analizate și să calculăm mărimea efectelor pentru fiecare comparație simplă realizată. Reținem faptul că va trebui să ajustăm pragul de semnificație prin metoda Bonferroni, împărțind pragul de semnificație clasic, $p = 0,05$ la numărul de comparații simple realizate.

Capitolul 12. Teste neparametrice pentru mai mult de două eșantioane perechi

12.1. Testul Friedman

12.1.1. Prezentare generală

Testul Friedman este utilizat pentru compararea a mai mult de două eșantioane perechi atunci când VD este ordinală sau cantitativă (în ultimul caz fie VD nu este normal distribuită, fie eșantioanele sunt de volum mic).

Condițiile aplicării testului Friedman sunt:


1. eșantioanele (sau variabilele) sunt perechi, fiecare subiect fiind testat de cel puțin trei ori
2. variabila dependentă este cantitativă sau ordinală.

Exemple. 1) Verificăm dacă există diferențe între preferințele elevilor pentru șase tipuri de muzică: disco, house, rap, jazz, clasică și operă, preferință măsurată pe aceeași scală ordinală. 2) Verificăm dacă există diferențe între copii, mame și tați în ceea ce privește valorizarea credinței.


12.1.2. Aplicarea testului Friedman

Să presupunem că analizăm influența minorității asupra opiniei majorității privind asumarea riscului. Deoarece un factor important al acestei influențe este persistența în timp, vom măsura opinia unei grupe de studenți la începutul anului 1, apoi la începutul anului 2 și, respectiv la începutul anului 3. În toată această perioadă doi studenți complici susțin asumarea riscului atunci când intervențiile lor în cadrul cursurilor și seminariilor permit acest lucru.

Deschidem fișierul *Influenta*. Calea în SPSS este: *Analyze* → *Nonparametric Tests* → *K Related Samples*.



Trecem variabilele *an1*, *an2* și *an3* în câmpul *Test Variable*, ne asigurăm că în câmpul *Test Type* este bifat testul *Friedman*, apoi clic *OK*.



12.1.3. Interpretarea outputului

Tabelul *Mean Ranks* prezintă mediile de rang pentru fiecare dintre cei trei ani ; observăm că anul 3 are media rangurilor cea mai ridicată (2,52), urmând anul 2 (1,84), iar pe ultimul loc anul 1 (1,64).

Ranks

	Mean Rank
AN1	1,64
AN2	1,84
AN3	2,52

În tabelul *Test Statistics* sunt prezentate rezultatele la testul Friedman: $\chi^2(2) = 12,819$, $p = 0,002$; prin urmare există diferențe semnificative între cele trei măsurători în ceea ce privește importanța asumării riscului.

Test Statistics^a

N	25
Chi-Square	12,819
df	2
Asymp. Sig.	,002

a. Friedman Test

Neajunsurile testului Friedman sunt aceleași cu ale testului Kruskal-Wallis: nu este posibilă calcularea directă a mărimii efectului și nu știm exact între care dintre cele trei măsurători sunt semnificative diferențele. Inspectând mediile de rang din primul tabel vom ști că există diferențe între anul 1 și anul 3, însă nu știm dacă există diferențe și între anul 2 și anul 3. Ar trebui să verificăm prin comparații două câte două fiecare dintre cele trei măsurători, aplicând testul Wilcoxon pentru două eșantioane perechi. Nu vom uita de corectarea pragului de semnificație în funcție de numărul de comparații (în acest caz trei), astfel că rezultatele la testul Wilcoxon vor fi raportate la pragul $p = 0,05/3 = 0,0166$. Prezentarea rezultatelor se va face la fel ca în cazul testului Kruskal-Wallis.

12.2. Testul Cochran Q

12.2.1. Prezentare generală

Testul Cochran Q este folosit pentru compararea a mai mult de două eșantioane perechi atunci când VD este dihotomică (răspunsuri binare de genul da/nu, succes/eșec etc.), fiind o extensie a testului McNemar.


Condițiile de aplicare a testului Cochran Q sunt:

1. eșantioanele (sau variabilele) sunt perechi, fiecare subiect fiind testat de cel puțin trei ori
2. variabila dependentă este dihotomică.

Exemple. 1. Vrem să aflăm în ce măsură trei personalități din spațiul politic (Traian Băsescu, Călin Popescu-Tăriceanu și Mircea Geoană) sunt percepute diferit în ceea ce privește integritatea acestora. Variantele de răspuns sunt dihotomice, de tipul: 1 = „este o persoană integră” și 0 = „nu este o persoană integră”.

12.2.2. Aplicarea testului Cochran Q

Ne propunem să analizăm dacă există diferențe între trei tipuri de intervenții (placebo, aspirină și antibiotic) asupra acelorași subiecți în ceea ce privește succesul/eșecul în tratarea răcelii. Deschidem fișierul *tratament*. Calea în SPSS este : *Analyze* → *Nonparametric Tests* → *K Related Samples*. Trecem variabilele *placebo*, *aspirină* și *antibiotic* în câmpul *Test Variable*, în câmpul *Test Type* bifăm testul *Cochran Q* (deselectând testul *Friedman*), apoi clic *OK*.



12.2.3. Interpretarea outputului

Tabelul *Frequencies* prezintă numărul de subiecți din fiecare celulă obținută prin încrucișarea celor două variabile. Observăm că din cei 20 de subiecți, metoda placebo a condus la eșec în 14 cazuri și succes în doar 6 cazuri în tratarea răcelii. De asemenea, tratarea cu aspirină a avut eșec în tratarea răcelii în 12 cazuri, iar succes în 8 cazuri. Totodată, tratarea cu antibiotice a avut eșec în tratarea răcelii în 7 cazuri, iar succes în 13 cazuri. Se observă astfel că metoda cea mai indicată în tratarea răcelii este dată de antibiotice, urmând apoi aspirina, iar pe ultimul loc metoda placebo.

Frequencies

	Value	
	0 = eșec	1 = succes
PLACEBO	14	6
ASPIRINA	12	8
ANTIBIOT	7	13

În tabelul *Test Statistics* sunt prezentate rezultatele la testul Cochran Q de comparare a celor trei metode de tratare a răcelii. Observăm că există diferențe semnificative între

cele trei metode de intervenție în ceea ce privește succesul sau eșecul în tratarea răcelii, Cochran Q (2) = 7,800, $p = 0,020$.

Test Statistics

N	20
Cochran's Q	7,800 ^a
df	2
Asymp. Sig.	,020

a. 1 is treated as a success.

Și acest test are aceleași neajunsuri ca testul Friedman: fiind un test omnibus, nu știm exact între care dintre cele trei tipuri de tratament diferențele sunt semnificative, pentru aceasta trebuind să aplicăm testul McNemar (corectând pragul de semnificație în funcție de numărul de comparații efectuate).

Exerciții SPSS

Teste neparametrice

1. Deschideți fișierul *Candidați*. Verificați dacă în urma unei dezbateri TV s-au schimbat opțiunile alegătorilor privind candidații la președinție A și B.
2. Deschideți fișierul *Valori*. Verificați dacă există diferențe în funcție de variabilele *sex* și *mediu* în ceea ce privește importanța acordată valorilor *veselie* și *imaginație*.
3. Deschideți fișierul *Valori*. Verificați dacă există diferențe în ceea ce privește aprecierea valorilor *veselie* și *imaginație* și de asemenea *autocontrol* și *imaginație*.
4. Deschideți fișierul *tip_familie*. Verificați dacă numărul de absențe al elevilor dintr-un eșantion (variabilă cu două categorii: 1 = mai puțin de 20 absențe, 2 = peste 20 de absențe) depinde de tipul de familie din care face parte (1 = familie nucleară, 2 = familie monoparentală).

Capitolul 13. ANOVA simplă (One-Way ANOVA)

13.1. Prezentare generală

Metoda ANOVA One-Way este echivalentă testului t pentru eșantioane independente și se aplică atunci când VI este de tip nominal sau ordinal, cu trei sau mai multe categorii.

Scopul acestei metode îl reprezintă testarea diferențelor între mediile a trei sau mai multe grupuri independente, verificarea efectului unei VI asupra unei VD pentru design intergrupuri. Treptele VI pot fi atât condiții experimentale (de exemplu, grup de control, intervenție experimentală 1, intervenție experimentală 2) – în cazul planurilor experimentale –, cât și categorii *naturale* (de exemplu, etnia: român, maghiar, rrom) sau *construite* (grupuri de subiecți cu stimă de sine ridicată, medie și scăzută).

Condiții necesare pentru aplicarea tehnicii ANOVA simplă:

1. Există o singură variabilă dependentă, aceasta fiind cantitativă.
2. Există o singură variabilă independentă, aceasta fiind nominală sau ordinală cu cel puțin trei nivele/trepte
3. VD este cantitativă și normal distribuită pentru fiecare dintre treptele VI. Dacă VD nu este normal distribuită sau grupele experimentale conțin un număr redus de subiecți (de exemplu, $N = 7$) se recomandă aplicarea testelor echivalente neparametrice (de exemplu, testul Kruskal-Wallis).
4. Omogenitatea varianțelor: varianțele VD trebuie să fie relativ egale pentru fiecare dintre grupele supuse comparației. Această condiție este verificată în SPSS cu ajutorul testului Levene. Dacă rezultatul la testul Levene este *nesemnificativ statistic* ($p > ,05$), atunci condiția omogenității varianțelor este îndeplinită.
5. Independența măsurătorilor: fiecare subiect este măsurat o singură dată.

Observație. Deși omogenitatea varianțelor este una dintre condițiile necesare aplicării metodei ANOVA, unii autori consideră că metoda ANOVA este suficient de robustă pentru a putea fi aplicată chiar și în condițiile încălcării acestei condiții.

Exemple. 1) Verificăm dacă există diferențe în ceea ce privește performanța școlară a elevilor în funcție de stilul parental din familie (democratic, autoritar, indulgent și neglijent). 2) Verificăm dacă trei metode moderne de predare conduc la performanțe școlare mai ridicate în rândul elevilor comparativ cu metodele tradiționale de predare.

Modul de operare al tehnicii ANOVA are la bază analiza diferitelor surse din care apare variația în scoruri: varianța totală = varianța intergrupuri (between-groups variance) + varianța intragrupuri (within-groups variance) = varianța explicată + varianța neexplicată. Atunci când varianța explicată este mult mai mare decât varianța

neexplicată, putem considera că diferențele dintre grupuri sunt semnificative (testul F face raportul celor două varianțe)¹.

Există două etape în aplicarea ANOVA simplă: *mai întâi* verificăm dacă există diferențe la nivel global între grupuri (dacă respingem H_0) prin intermediul testului F omnibus. *Apoi*, dacă răspunsul este afirmativ (rezultatul la testul F omnibus este semnificativ statistic), pentru a afla care dintre grupuri diferă între ele vom recurge la *procedura comparațiilor analitice, multiple*. Există două categorii de comparații:

1) *comparațiile planificate, a priori* numite *contraste* și 2) *comparațiile post hoc*. Contrastele testează ipoteze pe care cercetătorul le-a lansat înaintea cercetării privind diferențele de medie dintre anumite grupuri. În comparațiile post hoc, pe de altă parte, cercetătorul nu are o ipoteză unidirecțională lansată anterior (pe baza teoriei) privind diferențele de medie dintre anumite grupuri și pur și simplu explorează toate diferențele posibile dintre mediile grupurilor analizate.

13.2. Testele post hoc (neplanificate)

Neavând lansată o ipoteză unidirecțională privind diferențele dintre anumite grupuri, prin intermediul testelor post hoc verificăm existența unor diferențe semnificative între toate perechile de grupuri, acestea fiind disponibile în SPSS prin activarea butonului *Post Hoc*.

Testele post hoc sunt în număr de 20 și diferă după puterea lor (puterea de a descoperi diferențe semnificative atunci când acestea există) și probabilitatea de a produce eroarea de tipul I. Ele sunt grupate după criteriul egalității varianțelor (16 pentru cazul varianțelor egale și 4 pentru cazul varianțelor inegale).

Există două tipuri de proceduri post hoc: unul care testează diferența dintre fiecare pereche de medii (aceasta ne interesează în general) și altul care identifică subseturi omogene de medii (care nu diferă unele de altele). Unele dintre teste au la bază doar prima procedură (LSD, Bonferroni, Sidak, Dunnett – cu cele 3 variante –, Tamhane, Dunnett T3, Games-Howell, Dunnett C), altele doar a doua procedură (R-E-G-W F, R-E-G-W Q, S-N-K, Tukey b, Duncan, Waller-Duncan), iar altele au la bază ambele proceduri (Scheffe, Tukey, Hochberg GT2, Gabriel). Testele care urmează prima procedură testează diferența dintre fiecare pereche de medii și prezintă rezultatele sub forma unei matrice în care asterixul indică diferențele semnificative dintre medii la pragul $p = 0,05$.

Un caz special este testul Dunnett – aplicabil în cazul experimentelor cu grup de control – care compară toate grupurile cu unul dintre ele, considerat de control. Implicit, ultimul grup este considerat de control, însă această setare poate fi schimbată – se poate lua drept reper primul grup. Există trei variante de aplicare: una în care toate mediile sunt comparate cu media grupului de control, una în care doar mediile mai mari vor fi comparate cu media grupului de control și o alta în care doar mediile mai mici vor fi raportate la media grupului de control. Astfel, în primul caz ipotezele vor fi bidirecționale, iar în celelalte două cazuri ipotezele vor fi unidirecționale.

1. Pentru modalitatea de calcul a celor două varianțe vezi Lungu (2000).

Cum alegem testul potrivit dintre toate cele existente? Majoritatea autorilor recomandă – în cazul egalității varianțelor – folosirea testelor Bonferroni (Norusis, 1993; Lungu, 2002) și Tukey (Dancey și Reidy, 2002; Page, Braver și MacKinnon, 2003). Opțiunea pentru unul dintre cele două teste este în funcție de numărul de trepte (categorii) ale VI. Dacă VI are un număr redus de categorii se aplică testul Bonferroni, care este mai puternic în detectarea diferențelor dintre medii atunci când numărul de comparații este redus. Dacă VI are un număr mai mare de categorii (numărul de comparații este mai mare), atunci testul Tukey este mai puternic în detectarea diferențelor existente¹. Cu toate acestea, majoritatea cercetătorilor optează pentru testul Tukey.

Sava (2004) prezintă alte două criterii de alegere a testului potrivit: omogenitatea dispersiilor și numărul egal de subiecți din grupele cercetării (subiecți egali, relativ inegali, profund inegali). Astfel, atunci când varianțele sunt egale, se recomandă utilizarea următoarelor teste: Tukey în cazul grupurilor egale, Gabriel în cazul grupurilor relativ inegale și Hochberg GT2 în cazul grupurilor profund inegale. Când varianțele sunt inegale, sunt recomandate testele Dunnett T3 în cazul grupurilor egale și Games-Howell în cazul grupurilor inegale. Decizia alegerii testului potrivit devine simplă în acest moment, numărul de subiecți din grupe fiind cunoscut din designul studiului, iar omogenitatea dispersiilor fiind testată prin testul Levene după cum vom vedea în continuare.

Tabelul 13.1. Modul de selecție a testelor post hoc în funcție de omogenitatea dispersiilor și egalitatea numărului de subiecți din grupe (Sava, 2004)

		Numărul de subiecți		
		Egali (ex. 10, 10, 10)	Relativ inegali (ex. 11, 10, 9)	Profund inegali (ex. 15, 10, 7)
Omogenitatea dispersiei	dispersii egale	Tukey	Gabriel, Tukey b	Hochberg GT2
	dispersii inegale	Dunnett T3	Games-Howell	Games-Howell

De ce nu aplicăm teste t pentru eșantioane independente și preferăm aplicarea testelor post hoc? Mai întâi, pentru că dacă VI ar avea, de exemplu, patru categorii ar fi necesară aplicarea a șase teste t, așadar numărul de teste t necesare ar crește destul de mult odată cu creșterea numărului de categorii ale VI. Apoi, odată cu aplicarea testelor t obișnuite pentru mai mult de două grupuri crește probabilitatea de a comite eroarea de tipul I (respingerea ipotezei nule atunci când ea nu ar trebui respinsă): această probabilitate ar depăși limita maximă acceptată de 0,05. Dacă totuși am aplica teste t, în cazul a șase comparații, pentru evitarea erorii de tipul I ar trebui să ajustăm pragul de semnificație la care vom raporta rezultatele prin corecție Bonferroni, împărțind valoarea standard $p = 0,05$ la numărul de comparații efectuate, am obține un nou prag de semnificație la care ne

vom raporta, $p_{ajustat} = \frac{0,05}{6} = 0,008$, însă în această situație ar crește probabilitatea de a

1. Conform *SPSS Base 12.0 User's Guide* (2003, p. 369) și Field (2006, p. 275).

comite eroarea de tipul II. Testele post hoc rezolvă ambele probleme : printr-o singură operație sunt efectuate toate comparațiile posibile și calculate testele de semnificație ; pe de altă parte, aceste teste au la bază anumite corecții pentru a evita creșterea riscului de a produce eroarea de tipul I.

13.3. Testele de contrast sau comparațiile a priori (planificate)¹

Aceste teste sunt folosite atunci când ipotezele sunt unidirecționale, stabilite anterior derulării cercetării (de exemplu, familiarizarea cu tipul de itemi dintr-un test docimologic conduce la creșterea performanței studenților la test)

Contrastele sunt folosite pentru a testa relațiile dintre medii. Un contrast ψ este o combinație liniară a mediilor M_i , cu coeficienții de contrast a_i , astfel că :

$$\psi = a_1M_1 + a_2M_2 + \dots + a_iM_i = 0, \text{ unde } a_1 + a_2 + \dots + a_i = 0 \quad (13.1)$$

Prin intermediul contrastelor putem compara :

- a) media unui grup cu media altui grup (de exemplu, M_1 versus M_2) ;
- b) media unui grup cu media generală a unor alte grupuri [de exemplu, M_1 versus $(M_2 + M_3)/2$] ;
- c) media generală a unor grupuri cu media generală a altor grupuri [de exemplu, $(M_1 + M_4)/2$ versus $(M_2 + M_3)/2$].

Regulile de alocare a coeficienților sunt următoarele :

1. grupurile situate la stânga cuvântului *versus* primesc fiecare același coeficient cu semnul pozitiv
2. grupurile situate la dreapta cuvântului *versus* primesc fiecare același coeficient cu semnul negativ ; conform condițiilor 1 și 2, grupurile care au coeficienți pozitivi vor fi comparate cu grupurile care au coeficienți negativi
3. grupurile nementionate în comparație primesc toate coeficientul zero
4. pentru regulile 1 și 2, coeficientul este egal cu numărul de grupuri situate de partea cealaltă a cuvântului *versus* ;
5. suma coeficienților este egală cu zero (Page, Braver și MacKinnon, 2003).

De exemplu, într-un experiment în care avem două grupuri experimentale (G_1 și G_2) pe care testăm două noi metode de optimizare a învățării și un grup de control (G_3), într-o primă fază putem verifica dacă oricare dintre cele două metode dau rezultate mai bune comparativ cu neaplicarea lor (grupul de control) iar într-o a doua fază verificăm dacă una dintre cele două noi metode este mai eficientă comparativ cu cealaltă. Primul contrast ar fi (1, 1, -2), iar al doilea (1, -1, 0). Dacă ar exista șase grupuri și dorim să comparăm grupurile G_1 , G_5 cu G_2 , G_3 , G_4 , coeficienții de contrast ar fi (3, -2, -2, -2, 3, 0).

Există trei criterii în funcție de care pot fi clasificate testele de contrast.

- a) după criteriul complexității, există contraste simple și complexe :

1. Vezi și Sava (2004, pp. 97-106).

- *Contrastele simple* sau *pereche* reprezintă o comparație implicând doar două medii. În exemplul anterior (VI are trei categorii), comparăm, de exemplu, media grupului 2 cu media grupului 3; coeficienții de contrast vor fi: $(0,1,-1)$. Numărul

maxim de contraste simple este $\frac{k(k-1)}{2}$, k fiind numărul de grupuri.

- *Contrastele complexe* (o comparație implicând mai mult de două medii) reprezintă o combinație liniară a mediilor grupelor semnificative din studiul realizat. Dacă am compara eficiența a trei noi programe de formare cu un program tradițional, ar exista trei grupe experimentale (G_1, G_2, G_3) și un grup de control (G_4). Vom compara toate cele trei grupe experimentale (de fapt, media mediilor celor trei grupuri) cu grupul de control (cu media acestuia) astfel: $1 \cdot G_1 + 1 \cdot G_2 + 1 \cdot G_3 - 3 \cdot G_4$, coeficienții de contrast fiind $(1,1,1,-3)$. Numărul maxim de contraste complexe este mai mare de $\frac{k(k-1)}{2}$ pentru mai mult de trei grupuri.

b) după criteriul ortogonalității, există contraste ortogonale și contraste nonortogonale:

- *Contrastele ortogonale* sunt contraste independente, nonredundante. Un set de contraste este ortogonal dacă fiecare contrast este independent de oricare altul.
 - Două contraste $\psi_1 = (a_1, a_2, a_3, \dots, a_m)$ și $\psi_2 = (b_1, b_2, b_3, \dots, b_m)$ sunt ortogonale dacă

$$\sum_{i=1}^m (a_i b_i) = 0 \text{ sau } a_1 b_1 + a_2 b_2 + a_3 b_3 + \dots + a_m b_m = 0 \quad (13.2)$$

Să verificăm, de exemplu, ortogonalitatea următoarelor două contraste, $\psi_1 = (3, -2, -2, -2, 3)$ și $\psi_2 = (0, 2, -1, -1, 0)$.

Vom înmulți coeficienții pe coloană, și apoi vom face suma. Rezultatul va fi $(3) \cdot (0) + (-2) \cdot (2) + (-2) \cdot (-1) + (-2) \cdot (-1) + (3) \cdot (0) = 0$, prin urmare cele două contraste sunt ortogonale.

- Dacă am avea un singur contrast nestandardizat, acesta este în mod obligatoriu ortogonal (pentru că suma coeficienților este întotdeauna zero).
- Într-un set de contraste ortogonale, dacă un grup face parte dintr-un contrast, atunci el nu va mai face obiectul altei comparații.
- În cazul unui set de 4 contraste (de exemplu), acest set este ortogonal dacă fiecare contrast este ortogonal în raport cu oricare altul.
- Numărul maxim de contraste nestandardizate ortogonale ce pot fi realizate este $(k - 1)$, unde k este numărul de grupuri.
- Avantajul contrastelor ortogonale este că acestea mențin constantă eroarea setului de comparații la nivelul standard $\alpha = 0,05$. În schimb, contrastele nonortogonale cresc riscul de a produce eroarea de tipul I.
- *Contrastele nonortogonale* sunt acelea care nu respectă condiția (13.2). Astfel, suma produselor a două contraste (pe coloană) va fi diferită de zero.
 - Un set de contraste va fi nonortogonal dacă va conține cel puțin două contraste nonortogonale (suma produselor coeficienților este diferită de zero).
 - Numărul maxim de contraste nonortogonale este mai mare decât $(k - 1)$.

- Dezavantajul contrastelor nonortogonale este că nu mențin constantă eroarea de tipul I, trebuind să ajustăm pragul de semnificație la care raportăm rezultatele în funcție de numărul de contraste. Astfel, pentru 5 contraste nonortogonale, pragul de semnificație ajustat va fi $p = ,05/5 = ,01$.

c) după criteriul standardizării, există contraste standardizate și contraste nestandardizate :

- În cazul *contrastelor standardizate*, tipurile de comparații intergrupuri sunt deja specificate în SPSS (în meniul *Analyze* → *General Linear Model* → *Univariate*), acestea fiind :
 - *Deviation – contraste prin deviere (nonortogonale)* : compară media fiecărui grup (exceptând grupul de referință, care poate fi primul sau ultimul) cu media generală a tuturor grupurilor ;
 - *Simple – contraste simple (nonortogonale)* : compară media fiecărui grup cu media unui grup specificat (de referință), care poate fi primul sau ultimul. Acest contrast este util atunci când există un grup de control ;
 - *Difference – contrastele prin diferență (ortogonale)* : compară media fiecărui grup (exceptându-l pe primul) cu media generală a grupurilor anterioare ;
 - *Helmert – contrastele Helmert (ortogonale)* : compară media fiecărui grup (exceptându-l pe ultimul) cu media generală a grupurilor următoare ;
 - *Repeated – contrastele repetate (nonortogonale)* : compară media fiecărui grup (exceptându-l pe ultimul) cu media grupului următor ;
 - *Polynomial – contrastele polinomiale (ortogonale)* : reprezintă creșteri (sau descreșteri) liniare, curbilinii, cubice etc. de-a lungul unui set ierarhizat de medii (în acest caz, coeficienții au valorile fixe în SPSS). Vom putea testa, de exemplu, productivitatea în studii cantitative (ca o creștere liniară) pentru trei grupuri de cercetători : unii care nu au urmat nici un training în SPSS, alții care au beneficiat de un training de nivel mediu în SPSS și alții care au beneficiat de un training de nivel expert în SPSS. Vom reveni asupra acestor contraste.
- Pentru *contrastele nestandardizate*, cercetătorul însuși trebuie să specifice comparațiile urmărite prin intermediul introducerii coeficienților de contrast a_i în SPSS (în meniul *Analyze* → *Compare Means* → *One-Way ANOVA*)

Observații :

- Toate condițiile prezentate mai sus sunt specifice designurilor cu grupe egale de subiecți (*balanced design*). În cazul designurilor cu grupe inegale de subiecți (*unbalanced design*) apar câteva modificări. Astfel, condiția (13.1) devine $a_1n_1 + a_2n_2 + \dots + a_in_i = 0$ (13.3) (Lomax, 2001),

iar condiția (13.2) devine

$$\sum_{i=1}^m \frac{a_i b_i}{n_i} = 0 \quad \text{sau} \quad \frac{a_1 b_1}{n_1} + \frac{a_2 b_2}{n_2} + \frac{a_3 b_3}{n_3} + \dots + \frac{a_m b_m}{n_m} = 0 \quad (13.4),$$

unde $n_1, n_2, \dots, n_m$ reprezintă cele m grupe din design.

- Observațiile de mai sus privind designurile cu grupe inegale pot fi ignorate de cele mai multe ori. Unii autori consideră că SPSS oferă rezultate corecte la testele statistice chiar în cazul inegalității grupelor, însă doar pentru designuri cu un singur factor (Page, Braver, MacKinnon, 2003). Remarcăm totuși că rezultatele testelor de contrast tind să fie ceva mai optimiste (designurile cu grupe egale de subiecți fiind mai puternice decât cele cu grupe inegale).
- Putem aplica teste de contrast fără a lua în calcul testul F omnibus. Rezultatul la testul F omnibus poate să nu fie semnificativ (deoarece ia în calcul toate comparațiile-pereche), în schimb rezultatele la anumite teste de contrast pot fi semnificative statistic.

13.4. Contraste polinomiale: analiza direcțională, de tendință (*trend analysis*)

Aceste contraste sunt standardizate, ortogonale, prezente în ambele meniuri (atât *One-Way* cât și *GLM*) și testează creșteri (sau descreșteri) liniare, curbilinii, cubice etc. de-a lungul unui set ordonat de medii.



Condițiile aplicării unei analize direcționale sunt :

1. VI trebuie să fie de tip ordinal ;
2. treptele VI sunt egal distanțate ;
3. numărul de subiecți din fiecare grupă este egal.

Condițiile 2 și 3 pot fi încălcate, însă în astfel de situații se impun criterii mai conservatoare ale pragurilor de semnificație, precum $p < 0,01$ (Sava, 2004).



Să presupunem că VI are patru categorii. Ideea care stă la baza analizei de tendință este de a potrivi o *funcție polinomială* la mediile celor patru condiții.

Cea mai simplă astfel de funcție este funcția *liniară* : aceasta este o linie dreaptă și presupune o evoluție constantă a mediilor VD de la o treaptă la alta a VI. Tendința liniară poate fi sub forma unei creșteri liniare (graficul *Creștere liniară*) sau a unei descreșteri liniare (graficul *Descreștere liniară*).





Următoarea funcție (în ordinea complexității) este funcția *curbilineară*, care are o „îndoitură” în mijloc – adică poate fi de forma unui „U” (tendință de descreștere

curbiliniară, graficul *Descreștere curbiliniară*) sau „U” inversat (tendență de creștere curbiliniară, graficul *Creștere curbiliniară*). VI are cel puțin trei grupuri.



O altă funcție mai complexă este funcția *cubică*, care are două „îndoituri”, două schimbări de sens ale tendinței : 1) ascendent-descendent-ascendent – tendința de creștere cubică (graficul *Creștere cubică*) și 2) descendent-ascendent-descendent – tendința de descresștere cubică (graficul *Descreștere cubică*). VI are cel puțin patru grupuri.



Alte tendințe în ordinea creșterii gradului de complexitate sunt cele de ordinul 4 (cu trei schimbări de direcție sau „îndoituri”, iar VI are cel puțin cinci grupuri), de ordinul 5 (cu patru schimbări de direcție sau „îndoituri”, iar VI are cel puțin șase grupuri), de ordinul 6 etc. Numărul minim de grupuri ale VI trebuie să fie mai mare cu o unitate decât ordinul unei tendințe analizate.

În cazul contrastelor polinomiale (a analizelor direcționale, de trend), ipotezele sunt formulate relativ la ordinea mediei grupurilor. Pentru contrastele liniare crescătoare, ipoteza ar fi că media primului grup este mai mică comparativ cu media grupului al doilea, care este mai mică comparativ cu media grupului al treilea etc. Asemenea ipoteze se numesc *ipoteze ordinale* (Braver, Sheets, 1993, *apud* Page, Braver, MacKinnon, 2003, p. 36). Pentru a testa o asemenea ipoteză, procedăm în trei pași. *La pasul 1*, verificăm tendința liniară prin intermediul testului polinomial. Dacă rezultatele la testul polinomial sunt ne semnificative, ne oprim aici. Dacă tendința liniară este semnificativă statistic, trecem la *pasul 2* în cadrul căruia comparăm mediile grupurilor pentru a vedea dacă aceste medii sunt în ordinea specificată. Dacă mediile grupurilor sunt în ordinea specificată și rezultatele la testul polinomial sunt semnificative, ne oprim aici. În cazul în care mediile nu sunt în ordinea specificată, trecem la *pasul 3*, în care verificăm dacă

această ordine încorectă reflectă neacceptarea reală a ipotezei ordinale sau dacă aceste medii nu respectă ordinea prezisă din cauza erorilor de eșantionare. Cum este puțin probabil ca mediile grupurilor să respecte exact mediile în populații, vom testa dacă oricare dintre aceste inversări (de ordine a mediilor) sunt suficiente pentru a nu accepta ipoteza ordinală. Astfel, la pasul 3 testăm semnificația inversărilor prin testarea fiecărei perechi adiacente de medii; în cazul a patru grupuri vom compara G_1 cu G_2 , G_2 cu G_3 și G_3 cu G_4 (putem de asemenea folosi contrastul „REPEATED”, dacă grupurile sunt în ordinea prezisă). Ipoteza nulă este că nu există nici o inversare, fiind de dorit ca H_0 să nu fie respinsă. Ca referință vom folosi pragul de semnificație $p = 0,016 (= 0,05/3$ pentru că testăm un număr de trei comparații). Dacă toate contrastele sunt ne semnificative, nu există nici o inversare semnificativă, iar ipoteza ordinală este acceptată (Page, Braver, MacKinnon, 2003). Doar în această situație rezultatele la testul polinomial aplicat sunt valide.

13.5. Mărimea efectului în cazul testelor de contrast și al testelor post hoc

În calcularea mărimii efectului vom folosi formulele 13.5 sau 13.6 de mai jos (Rosenthal, Rosnow și Rubin, 2000).

Atunci când VI are doar două trepte, indicatorul r al mărimii efectului este:

$$r = \sqrt{\frac{F}{F + df_{\text{intragrup}}}} = \sqrt{\frac{t^2}{t^2 + df_{\text{intragrup}}}} \quad (13.5)$$

Dacă VI are mai mult de două trepte și am aplicat teste de contrast sau post hoc, indicatorul r al mărimii efectului va fi:

$$r = \sqrt{\frac{F_{\text{contrast}}}{F_{\text{contrast}} + df_{\text{intragrup}}}} = \sqrt{\frac{t^2_{\text{contrast}}}{t^2_{\text{contrast}} + df_{\text{intragrup}}}} \quad (13.6).$$

13.6. Aplicarea metodei One-Way ANOVA


Într-un studiu verificăm dacă există diferențe în funcție de vârstă în ceea ce privește manifestarea comportamentelor prosociale. Vom aplica un chestionar care măsoară comportamentul prosocial pe un lot de 200 de subiecți, stratificat în funcție de variabila vârstă astfel: 50 de subiecți de 10-14 ani, 50 de subiecți de 15-19 ani, 50 de subiecți de 20-25 de ani și 50 de subiecți de 26-30 de ani.

Tabelul 13.2. Designul ANOVA simplă

Variabila		
Vârsta	11-15 ani	G1
	16-20 de ani	G2
	21-25 de ani	G3
	26-30 de ani	G4

Existând patru grupuri, ipoteza nulă H_0 va fi că mediile celor patru grupuri sunt egale. Ipoteza de cercetare H_1 este că mediile celor patru grupuri diferă între ele.

Deschidem fișierul *Comportament_prosocial*. Verificăm mai întâi condiția normalității distribuției VD pentru fiecare treaptă a VI. Călea în SPSS este: *Analyze* → *Descriptive Statistics* → *Explore*. Trecem variabila *prosocial* în câmpul *Dependent List*, iar variabila *varsta* în câmpul *Factor List*, activăm butonul *Plots*, iar aici bifăm *Normality plots with tests*; clic *Continue* și *OK*.



Rezultatele semnificative sunt prezentate în tabelul *Tests of Normality* de mai jos. Observăm că rezultatele la testul Shapiro-Wilk (care este mai puternic decât Kolmogorov-Smirnov) sunt nesemnificative statistic; prin urmare VD *prosocial* este normal distribuită pentru fiecare dintre treptele VI *varsta*; condiția 3 fiind îndeplinită, putem aplica ANOVA.


Tests of Normality

		Kolmogorov-Smirnov ^a			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
comportament prosocial	11 - 15 ani	,078	50	,200*	,973	50	,485
	16 - 20 ani	,083	50	,200*	,950	50	,067
	21 - 25 ani	,163	50	,002	,949	50	,060
	26 - 30 ani	,116	50	,093	,953	50	,090


*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Calea specifică în SPSS pentru ANOVA simplă este : *Analyze* → *Compare Means* → *One-Way ANOVA*.



Trecem VD *prosocial* în spațiul *Dependent List*, iar VI *varsta* în spațiul *Factor* (aceasta este variabila de grupare), apoi activăm butonul *Options* și în caseta de dialog bifăm *Descriptives*, *Homogeneity of variance test* și *Means plot*, apoi clic *Continue* și *OK*.



Primele două opțiuni bifate ne vor permite să verificăm dacă condiția omogenității varianțelor este îndeplinită, iar a treia face posibilă ilustrarea grafică a mediilor celor patru grupuri. În acest moment nu ne vom referi la butoanele *Contrasts* și *Post Hoc*, care conțin testele de comparare a grupurilor.

13.7. Interpretarea outputului

Tabelul *Descriptives* prezintă numărul de subiecți, media, deviația standard și eroarea standard, limitele intervalului de încredere a mediei și valorile minime și maxime pentru fiecare dintre cele patru grupuri, precum și pentru întregul eșantion. De exemplu, grupul de subiecți având vârsta cuprinsă între 11 și 15 ani obțin o medie de 54,60 la comportament prosocial etc.

Observăm că mediile sunt diferite. O inspectare a deviațiilor standard pentru cele patru grupuri ne indică o similaritate a acestora, ceea ce conduce la concluzia că varianțele celor patru grupuri ar fi omogene. Criteriul statistic pentru omogenitatea

varianțelor rămâne totuși testul Levene. Observăm că media pentru grupul 4 este mult mai mare decât mediile pentru grupurile 2 și 3 și, mai important, intervalul de încredere pentru media grupului 4 nu se suprapune cu cele corespunzătoare grupurilor 2 și 3. Astfel, diferențele semnificative ar putea fi între grupul 4 și grupurile 2 și 3.

Descriptives

comportament prosocial

	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
11 - 15 ani	50	54,60	7,29	1,03	52,53	56,67	41	73
16 - 20 ani	50	52,64	7,15	1,01	50,61	54,67	41	67
21 - 25 ani	50	52,90	8,02	1,13	50,62	55,18	32	66
26 - 30 ani	50	57,32	6,44	,91	55,49	59,15	47	75
Total	200	54,37	7,43	,53	53,33	55,40	32	75

Tabelul *Test of Homogeneity of Variances* prezintă rezultatul testului Levene de omogenitate a varianțelor, $Levene\ F(3, 196) = 0,954, p = 0,416 (p > 0,05)$; prin urmare varianțele sunt egale, iar condiția omogenității varianțelor este îndeplinită, așadar poate fi aplicată tehnica ANOVA.

Atenție! Pentru ca varianțele să fie relativ egale, trebuie ca rezultatul la testul Levene să fie nesemnificativ statistic la pragul $p \leq 0,05$.

Test of Homogeneity of Variances

comportament prosocial

Levene Statistic	df1	df2	Sig.
,954	3	196	,416

Tabelul principal din output ANOVA este analizat în continuare :

- suma pătratelor (Sum of Squares) – mai exact sumele deviațiilor pătrate de la medie – intergrupuri (SS_B), intragrupuri (SS_W) și per total ($SS_B + SS_W$);
- gradele de libertate (df) intergrupuri, intragrupuri și totale; $df_{\text{Between}} = (\text{numărul de grupuri} - 1) = (4 - 1) = 3$, $df_{\text{Within}} = (\text{numărul total de subiecți} - \text{numărul de grupuri}) = (210 - 4) = 206$, $df_{\text{Total}} = df_{\text{Between}} + df_{\text{Within}}$;
- varianțele (Mean Square) intergrupuri (MS_B) și intragrupuri (MS_W): varianța inter-

grupuri $MS_B = \frac{SS_B}{df_B}$, iar varianța intragrupuri $MS_W = \frac{SS_W}{df_W}$;


- rezultatul la testul F omnibus și pragul de semnificație ($F = \frac{MS_B}{MS_W}$); cum F este semnificativ, rezultă că există diferențe semnificative între grupuri în ceea ce privește manifestarea comportamentului prosocial, $F(3, 196) = 4,412, p < 0,05$.

ANOVA


comportament prosocial

	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	695,455	3	231,818	4,412	,005
Within Groups	10298,900	196	52,545		
Total	10994,355	199			

Graficul afișat de ANOVA este prezentat mai jos ; acesta conține pe axa OX cele patru grupe de vârstă, iar pe axa OY media variabilei *comportament prosocial*.



O altă reprezentare grafică frecvent utilizată este cea sub formă de bare, obținută pe calea *Graphs → Bar → Simple → Define* ; trecem variabila *varsta* în spațiul *Category Axis*, în câmpul *Bars Represent* activăm opțiunea *Other summary function*, apoi în spațiul *Variable* introducem *comportament prosocial* și clic *OK*.



Până acum, conform rezultatelor la testul F omnibus, știm că manifestarea comportamentului prosocial diferă în funcție de vârstă, media cea mai scăzută înregistrându-se la adolescenții de 16-20 de ani, iar cea mai ridicată la maturii de 26-30 de ani. Pentru a afla între care dintre aceste grupuri există diferențe semnificative vom recurge la *procedura comparațiilor analitice, multiple*, fie prin aplicarea testelor de contrast, fie prin aplicarea testelor post hoc.

13.8. Aplicarea testelor post hoc

Vom reaplica ANOVA, de această dată activând butonul *Post Hoc* și selectând testul *Tukey* (știm că varianțele sunt egale).

One-Way ANOVA: Post Hoc Multiple Comparisons

☒ Equal Variances Assumed

☐ LSD ☐ S-N-K ☐ Waller-Duncan
☐ Bonferroni ☒ Tukey Type I/Type II Error Ratio: 100
☐ Sidak ☐ Tukey's-b ☐ Dunnett
☐ Scheffe ☐ Duncan Control Category: Last
☐ R-E-G-W F ☐ Hochberg's GT2 Test:
☐ R-E-G-W Q ☐ Gabriel ☐ < Control ☐ > Control

☐ Equal Variances Not Assumed

☐ Tamhane's T2 ☐ Dunnett's T3 ☐ Games-Howell ☐ Dunnett's C

Significance level: .05

Continue Cancel Help

Rezultatele cele mai importante sunt prezentate în tabelul *Multiple Comparisons*, pe care îl vom analiza în continuare.

Multiple Comparisons

Dependent Variable: comportament prosocial

Tukey HSD

(I) varsta	(J) varsta	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
11 - 15 ani	16 - 20 ani	1,96	1,45	,530	-1,76	5,68
	21 - 25 ani	1,70	1,45	,644	-2,02	5,42
	26 - 30 ani	-2,72	1,45	,238	-6,44	1,00
16 - 20 ani	11 - 15 ani	-1,96	1,45	,530	-5,68	1,76
	21 - 25 ani	-,26	1,45	,998	-3,98	3,46
	26 - 30 ani	-4,68*	1,45	,007	-8,40	-,96
21 - 25 ani	11 - 15 ani	-1,70	1,45	,644	-5,42	2,02
	16 - 20 ani	,26	1,45	,998	-3,46	3,98
	26 - 30 ani	-4,42*	1,45	,012	-8,14	-,70
26 - 30 ani	11 - 15 ani	2,72	1,45	,238	-1,00	6,44
	16 - 20 ani	4,68*	1,45	,007	,96	8,40
	21 - 25 ani	4,42*	1,45	,012	,70	8,14

*. The mean difference is significant at the .05 level.

În prima coloană este prezentată matricea comparațiilor intergrupuri, iar în coloana a doua sunt afișate diferențele de medii corespunzătoare fiecărei comparații-pereche; diferențele semnificative sunt marcate cu un asterix. Următoarea coloană afișează eroarea standard corespunzătoare fiecărei diferențe de medii, în timp ce în coloana a patra sunt prezentate pragurile de semnificație corespunzătoare diferențelor de medii. Ultimele două coloane afișează limitele minime și maxime ale intervalului de încredere. Tabelul nu prezintă valoarea efectivă a testului t Tukey, însă aceasta poate fi calculată făcând raportul între diferența de medii și eroarea standard (cu ajutorul acestei formule se calculează valoarea testului t pentru toate testele post hoc, fie că e vorba despre testele Bonferroni, Tukey sau altele).

$$t_{\text{Tukey}} = \frac{\text{Mean\_Difference}}{\text{Std.\_Error}}$$

Constatăm că există diferențe semnificative între grupurile 16-20 de ani și 26-30 de ani, Tukey $t = 3,23$ ($= 4,68 / 1,45$), $p = 0,007$ și de asemenea între grupurile 21-25 de ani și 26-30 de ani, Tukey $t = 3,05$ ($= 4,42 / 1,45$), $p = 0,012$. Se observă că valoarea zero nu aparține intervalului de încredere atunci când diferența între medii este semnificativă. Cum din media grupului de referință se scade media celorlalte grupuri, vom ști că media grupului de 26-30 de ani este mai mare decât media grupurilor 16-20 de ani și 21-25 de ani (acest lucru poate fi remarcat și din tabelul *Descriptives* sau din grafic). Rezultatele la testul Tukey sunt prezentate în tabelul 13.3.

Tabelul 13.3. Rezultatele la testul post hoc Tukey

	11-15 de ani	16-20 de ani	21-25 de ani	26-30 de ani
11-15 ani (M = 54,60)	-	1,35	1,17	1,87
16-20 de ani (M = 52,64)		-	0,18	3,23*
21-25 de ani (M = 52,90)			-	3,05*
26-30 de ani (M = 57,32)				-

*p < 0,05

Vom calcula mărimea efectului în cazul fiecărei comparații semnificative conform

$$\text{formulei: } r = \sqrt{\frac{F_{\text{contrast}}}{F(df_{\text{intergrup}}) + df_{\text{intragrup}}}} = \sqrt{\frac{t^2_{\text{contrast}}}{F(df_{\text{intergrup}}) + df_{\text{intragrup}}}}$$

În cazul primei comparații semnificative, obținem:

$$r = \frac{3,23}{\sqrt{4,412 \cdot 3 + 196}} = \frac{3,23}{\sqrt{13,236 + 196}} = \frac{3,23}{\sqrt{209,236}} = \frac{3,23}{14,46} = 0,22$$

Pentru a doua comparație semnificativă, $r = 0,21$.

Rezultatele vor fi interpretate astfel: indivizii de 26-30 de ani manifestă comportamente prosociale într-o măsură semnificativ mai mare comparativ cu indivizii de 16-20 de ani, (Tukey $t = 3,23$, $p < 0,05$, $r = 0,22$) și cei de 21-25 de ani (Tukey $t = 3,05$, $p < 0,05$, $r = 0,21$).

13.9. Aplicarea testelor de contrast


Pe baza experienței ne așteptăm ca adulții de 26-30 de ani (având identitatea formată și dispunând de mai multe resurse, fie ele psihologice sau de altă natură) să manifeste comportamente prosociale într-o măsură mai mare comparativ cu subiecții din celelalte trei grupuri.

13.9.1. Aplicarea contrastelor nestandardizate neortogonale

Deoarece vom compara fiecare dintre primele trei grupuri cu G_4 contrastele vor fi *non-ortogonale*, iar coeficienții de contrast sunt:

- pentru G_1 versus G_4 : 1, 0, 0, -1;
- pentru G_2 versus G_4 : 0, 1, 0, -1;
- pentru G_3 versus G_4 : 0, 0, 1, -1.

În meniul *Analyze* → *Compare Means* → *One-Way ANOVA*, activăm butonul *Contrasts*. Introducem coeficientul pentru fiecare grup, apoi facem clic pe butonul *Add* și fiecare nouă valoare este adăugată în josul listei de coeficienți. Pentru a introduce al doilea set de coeficienți, clic pe *Next* și introducem coeficienții pentru al doilea contrast etc. Pentru a ne mișca între seturile de contraste, folosim butoanele *Next* și *Previous*. În final, caseta de dialog *One-Way ANOVA: Contrasts* va arăta astfel:



Ordinea coeficienților este importantă, deoarece corespunde ordinii ascendente a categoriilor VI. Primul coeficient din listă corespunde primei categorii a VI (grupului G_1), iar ultimul coeficient corespunde ultimei categorii a VI (grupului G_4). Rezultatele în output apar sub forma a două tabele.

Tabelul *Contrast Coefficients* afișează coeficienții corespunzători fiecărui grup, în cazul fiecărui contrast. Pe baza lor vom ști despre ce comparații este vorba.

Tabelul *Contrast Tests* prezintă rezultatele la testele t de contrast atât în cazul omogenității varianțelor, cât și în cazul eterogenității acestora. Sunt afișate diferențele de medii (Value of Contrast), erorile standard ale diferențelor de medii (Std. Error), rezultatele la testele t, gradele de libertate (df) și pragurile de semnificație (Sig.). Deoarece știm că varianțele sunt egale, vom urmări rezultatele din prima parte a tabelului. Cum contrastele sunt neortogonale, crește riscul de a se produce eroarea de tipul I. Pentru a controla acest risc, va trebui să procedăm la ajustarea de tip Bonferroni a

pragului de semnificație $p = \frac{0,05}{3} = 0,016$, iar la acesta din urmă vom raporta rezultatele obținute.

Observăm că rezultatele la contrastele 2 și 3 sunt semnificative statistic. Astfel, subiecții de 26-30 de ani manifestă comportamente prosociale într-o măsură mai mare comparativ cu subiecții de 16-20 de ani [$t(196) = 3,228$, $p < 0,016$] și comparativ cu subiecții de 21-25 de ani [$t(196) = 3,049$, $p < 0,016$]. Putem calcula și mărimea efectului pentru fiecare dintre cele două contraste semnificative aplicând formula 13.6. Vom obține un $r = 0,22$ pentru al doilea contrast și un $r = 0,21$ pentru al treilea contrast.

Contrast Tests

		Contrast	Value of Contrast	Std. Error	t	df	Sig. (2-tailed)
comportament prosocial	Assume equal variances	1	-2,72	1,45	-1,876	196	,062
		2	-4,68	1,45	-3,228	196	,001
		3	-4,42	1,45	-3,049	196	,003
	Does not assume equal variances	1	-2,72	1,38	-1,977	96,527	,051
		2	-4,68	1,36	-3,438	96,941	,001
		3	-4,42	1,45	-3,038	93,635	,003

Observație. Evitând eroarea setului de comparații și implicit eroarea de tipul I (prin ajustarea pragului de semnificație), creștem probabilitatea apariției erorii de tipul II: acceptarea ipotezei nule când aceasta ar fi trebuit respinsă; implicit, va scădea șansa de a detecta diferențe semnificative atunci când acestea există. Din acest motiv, este indicată aplicarea contrastelor ortogonale.

13.9.2. Aplicarea contrastelor nestandardizate ortogonale

Pe baza experienței ne așteptăm ca manifestarea comportamentelor prosociale să sporească odată cu vârsta. O excepție ar putea fi între grupele de vârstă 11-15 ani și 16-20 de ani, unde experiența în consiliere psihopedagogică ne spune că tendința ar fi de descreștere datorită influenței mai puternice a educației morale la elevii de gimnaziu și a egocentrismului adolescenților. Prima ipoteză lansată este că adulții (26-30 de ani) manifestă comportamente prosociale într-o măsură mai mare comparativ cu subiecții de vârste inferioare (11-25 de ani); vom compara grupurile G_1 , G_2 și G_3 (considerate global) cu G_4 , iar coeficienții de contrast vor fi (1, 1, 1, -3). A doua ipoteză va fi că subiecții de 21-25 de ani manifestă comportamente prosociale într-o măsură mai mare comparativ cu subiecții de vârste anterioare (11-20 de ani); vom compara G_1 și G_2 cu G_3 , iar coeficienții vor fi (1, 1, -2, 0). A treia ipoteză va fi că subiecții de 16-20 ani manifestă comportamente prosociale într-o măsură mai mică comparativ cu subiecții de 11-15 ani; vom compara G_1 cu G_2 , iar coeficienții vor fi (1, -1, 0, 0). În această situație, după cum putem vedea, *contrastele sunt ortogonale*, iar riscul producerii erorii de tipul I este menținut constant la valoarea 0,05.

Revenim în meniul One-Way ANOVA, clic pe butonul Reset pentru a anula vechile contraste, reintroducem variabilele și activăm butonul Contrasts, urmând apoi să introducem coeficienții de contrast. Rezultatele se prezintă în mod analog contrastelor nestandardizate neortogonale.


Să analizăm tabelul *Contrast Tests*. Observăm că doar rezultatele la primul test de contrast sunt semnificative statistic, ceea ce înseamnă că indivizii de 26-30 de ani manifestă comportamente prosociale într-o măsură semnificativ mai mare comparativ cu subiecții de vârste anterioare (11-25 de ani), $t(196) = 3,328$, $p < 0,001$, indicatorul r al mărimii efectului fiind (conform formulei 13.6) $r = 0,23$.

Contrast Tests


		Contrast	Value of Contrast	Std. Error	t	df	Sig. (2-tailed)
comportament prosocial	Assume equal variances	1	-11.82	3.55	-3.328	196	.001
		2	1.44	2.51	.573	196	.567
		3	1.96	1.45	1.352	196	.178
	Does not assume equal variances	1	-11.82	3.29	-3.590	96.633	.001
		2	1.44	2.69	.535	89.441	.594
		3	1.96	1.44	1.357	97.964	.178

13.9.3. Aplicarea contrastelor standardizate

Menținem ipotezele lansate în cadrul contrastelor nestandardizate ortogonale și le vom verifica prin intermediul noilor contraste. Deschidem meniul *Analyze* → *General Linear Model* → *Univariate*.



Introducem variabila *comportament prosocial* în câmpul *Dependent Variable*, iar variabila *varsta* în câmpul *Fixed Factor(s)*, apoi activăm butonul *Contrast*, iar din câmpul *Change Contrast* selectăm *Difference* clic pe butonul *Change* pentru setarea contrastului ales, clic *Continue* și *OK*.



Rezultatele care ne interesează se regăsesc în tabelele următoare.

Tabelul *Contrast Results (K Matrix)* prezintă rezultatele celor trei contraste. Primul contrast compară G_2 cu G_1 , al doilea contrast compară G_3 cu grupurile anterioare, iar al treilea compară G_4 cu grupurile anterioare. Sunt prezentate estimări ale diferențelor de medii (*Contrast Estimate* = $M_2 - M_1$ pentru primul contrast), valoarea de referință pentru testarea ipotezei nule conform căreia diferența de medii este zero (*Hypothesized Value*), diferența dintre estimările diferențelor de medii și valoarea de referință, eroarea standard a diferențelor dintre medii (*Std. Error*), pragul de semnificație (*Sig.*), precum și limitele inferioare și superioare ale intervalelor de încredere corespunzătoare diferențelor de medii (*95% Confidence Interval for Difference*). Observăm că doar contrastul al

treilea este semnificativ statistic, cel care compară G_4 cu primele trei grupuri considerate global, $p = 0,009$. Pentru a calcula valoarea testului t în cazul fiecărui contrast facem raportul dintre estimarea contrastului și eroarea standard a diferenței dintre medii:

$$t = \frac{\text{Contrast Estimate}}{\text{Std. Error}}$$

Astfel, pentru contrastul al treilea $t = \frac{3,940}{1,184} = 3,328$, $p = 0,001$. După cum se observă, rezultatele obținute sunt conforme cu cele obținute în cazul testelor de contrast nestandardizate ortogonale de mai sus.

Contrast Results (K Matrix)

		Dependent Variable
varsta Difference Contrast		comportament prosocial
Level 2 vs. Level 1	Contrast Estimate	-1.960
	Hypothesized Value	0
	Difference (Estimate - Hypothesized)	-1.960
	Std. Error	1.450
	Sig.	.178
	95% Confidence Interval for Difference	-4.819
	Lower Bound Upper Bound	.899
Level 3 vs. Previous	Contrast Estimate	-.720
	Hypothesized Value	0
	Difference (Estimate - Hypothesized)	-.720
	Std. Error	1.256
	Sig.	.567
	95% Confidence Interval for Difference	-3.196
	Lower Bound Upper Bound	1.756
Level 4 vs. Previous	Contrast Estimate	3.940
	Hypothesized Value	0
	Difference (Estimate - Hypothesized)	3.940
	Std. Error	1.184
	Sig.	.001
	95% Confidence Interval for Difference	1.606
	Lower Bound Upper Bound	6.274

Următorul tabel *Test Results* reia rezultate prezentate anterior în tabelul ANOVA: varianțele intergrupuri (Contrast) și intragrupuri (Error), precum și rezultatele la testul F general.

Test Results

Dependent Variable: comportament prosocial

Source	Sum of Squares	df	Mean Square	F	Sig.
Contrast	695.455	3	231.818	4.412	.005
Error	10298.900	196	52.545		

13.10. Prezentarea rezultatelor

Pentru a verifica dacă există diferențe semnificative în ceea ce privește comportamentul prosocial al subiecților în funcție de grupa de vârstă am aplicat metoda analizei de varianță ANOVA One-Way.

Pe baza rezultatelor obținute, s-a constatat că există diferențe semnificative statistic în funcție de variabila *varsta* în ceea ce privește comportamentul prosocial [$F(3, 194) = 4,412$, $p < 0,05$] (tabelul 13.5). Pentru a verifica între care dintre cele patru grupe de vârstă sunt semnificative diferențele am aplicat testul post hoc *t* Tukey. Rezultatele obținute au evidențiat existența unor diferențe semnificative între indivizii de 26-30 de ani, pe de o parte, și cei de 16-20 de ani și 21-25 de ani, pe de altă parte în ceea ce privește manifestarea comportamentului prosocial (tabelul 13.6). Astfel, indivizii având vârsta cuprinsă între 26 și 30 de ani manifestă comportamente prosociale într-o măsură semnificativ mai mare comparativ cu indivizii de 16-20 de ani (Tukey $t = 3,23$, $p < 0,05$, $r = 0,22$) și cei de 21-25 de ani (Tukey $t = 3,05$, $p < 0,05$, $r = 0,21$). În tabelul 13.4. sunt prezentate mediile, abaterile standard și numărul de subiecți pentru fiecare grup precum și per total.

Tabelul 13.4. Mediile și abaterile standard pentru variabila *comportament prosocial*, în funcție de variabila *vârstă*

Vârsta	n	Comportament prosocial	
		M	SD
11-15 ani	50	54,60	7,29
16-20 de ani	50	52,64	7,15
21-25 de ani	50	52,90	8,02
26-30 de ani	50	57,34	6,44
Total	200	54,37	7,43

Tabelul 13.5. Analiza de varianță ANOVA One-Way pentru compararea mediilor la variabila *comportament prosocial* în funcție de variabila *vârstă*

Sursa varianței	SS	df	MS	F	p
Intergrupuri	695,455	3	231,818	4,412	0,005
Intragrupuri	10298,900	196	52,545		
Total	10994,355	199			

Tabelul 13.6. Rezultatele la testul post hoc *t* Tukey

	11-15 ani	16-20 de ani	21-25 de ani	26-30 de ani
11-15 ani (M = 54,60)	-	1,35	1,17	1,87
16-20 de ani (M = 52,64)		-	0,18	3,23*
21-25 de ani (M = 52,90)			-	3,05*
26-30 de ani (M = 57,32)				-

* $p < 0,05$

Capitolul 14. Analiza de varianță ANOVA factorială

14.1. Prezentare generală

Prin intermediul tehnicii ANOVA factoriale putem analiza efectele a două sau mai multe VI asupra unei VD, precum și efecte de interacțiune ale VI asupra VD. De exemplu, în cazul a două VI cu două nivele fiecare, putem verifica dacă există un efect de dublă interacțiune a celor două VI asupra VD, în sensul că una dintre VI influențează diferit VD în cele două condiții ale celeilalte VI.

Condițiile necesare pentru aplicarea ANOVA factorială sunt aceleași ca pentru ANOVA simplă.

Sursele de varianță în ANOVA factorială sunt : 1) varianța corespunzătoare fiecărei VI ; 2) varianța corespunzătoare efectelor de interacțiune și 3) varianța eroare sau intragrupuri. Primele două surse reprezintă varianța intergrupuri. De exemplu, într-un design cu două VI (A și B), varianța totală este descompusă astfel :

- varianța atribuită variabilei A ;
- varianța atribuită variabilei B ;
- varianța atribuită interacțiunii dintre variabilele A și B ;
- varianța eroare (sau varianța intragrupuri).

În ANOVA simplă exista o singură VI și un singur test F care compară (raportează) varianța atribuită VI (varianța intergrupuri) cu varianța intragrupuri. Atunci când varianța intergrupuri era semnificativ mai mare decât varianța intragrupuri, testul F era semnificativ, iar efectul VI asupra VD (diferențele între grupuri) era datorat manipulării experimentale, și nu erorilor de eșantionare.

În ANOVA factorială, logica este aceeași. De exemplu, dacă verificăm influența a două VI (A și B) asupra VD, ANOVA compară fiecare dintre cele trei surse de varianță intergrupuri (cea datorată variabilei A, cea datorată variabilei B și cea datorată interacțiunii variabilelor A și B) cu varianța eroare, calculând trei teste F. Când una dintre cele trei variante intergrupuri este considerabil mai mare decât varianța eroare, testul F corespunzător va fi semnificativ. Vom putea testa astfel :





- efectul variabilei A asupra VD – numit și efectul principal al variabilei A ;
- efectul variabilei B asupra VD – numit și efectul principal al variabilei B ;
- efectul de interacțiune a variabilelor A și B.

În cazul unui design cu trei VI, vom testa trei efecte principale, trei efecte de dublă interacțiune și un efect de triplă interacțiune.

Un design cu două VI, fiecare având două nivele, se exprimă sub forma 2×2 , unul cu trei VI în care primele două au câte două nivele, iar a treia VI cu trei nivele este de forma $2 \times 2 \times 3$ etc. Pot exista și designuri cu mai mult de trei VI (de exemplu, design cu cinci VI de forma $2 \times 2 \times 2 \times 3 \times 3$), însă în asemenea condiții se recomandă aplicarea regresiei multiple, și nu ANOVA factorială din cauza dificultăților întâmpinate în interpretarea efectelor de interacțiune (vom vedea în continuare).

Interacțiunea dintre variabile

Atunci când interacțiunea dintre variabile este semnificativă, este primordială interpretarea acesteia, interpretarea efectelor principale semnificative făcându-se cu precauție și doar în cazul în care acestea sunt importante în contextul cercetării. Prezentăm mai jos câteva ilustrări grafice corespunzătoare interacțiunii dintre două variabile. Situația (a) sugerează că nu există interacțiune între variabilele A și B (liniile sunt paralele), în vreme ce situațiile (b), (c) și (d) sugerează că există o interacțiune între variabilele A și B (cele două linii se intersectează sau tind să se intersecteze). Interpretarea unei interacțiuni semnificative se poate face din două perspective – fie a variabilei A, fie a variabilei B –, cercetătorul alegând una dintre aceste variante în funcție de scopul cercetării (interpretarea din dubla perspectivă oferind informații redundante).



Analizarea efectelor principale semnificative se face prin intermediul testelor de contrast sau a testelor post hoc, precum în ANOVA simplă.

În cazul efectelor de interacțiune semnificative, analiza acestora urmează două demersuri: 1) analiza efectelor simple, 2) analiza contrastelor de interacțiune (Page, Braver și MacKinnon, 2003).

14.2. Aplicarea metodei ANOVA factorială


Ne propunem să verificăm influența *autonomiei în învățare* și a *internalismului-externalismului* asupra *performanței școlare* la elevii de liceu. Vom realiza un experiment cu trei grupe experimentale în cadrul cărora vom aplica trei metode de predare diferite în funcție de gradul de autonomie în învățare oferit elevilor: autonomie scăzută, medie și ridicată. Aplicăm de asemenea un chestionar care măsoară internalismul-externalismul elevilor, iar pe baza acestuia selectăm subiecții internaliști și externaliști care vor fi distribuiți în mod egal în cadrul condițiilor experimentale. Designul cercetării este de tipul 3×2 și este prezentat în tabelul 14.1.

Tabel 14.1. Designul cercetării 3×2

	Autonomie scăzută	Autonomie medie	Autonomie ridicată
Internalism	G1	G3	G5
Externalism	G2	G4	G6

Vom verifica dacă odată cu creșterea gradului de autonomie în învățare, performanța va crește la subiecții internaliști și se va diminua la subiecții externaliști.

Deschidem fișierul *ANOVA factoriala_1*. VI sunt *autonomia* (autonom) și *internalismul-externalismul* (ie), iar VD este *performanța* (perform). Calea în SPSS este: *Analyze* → *General Linear Model* → *Univariate*.



În câmpul *Dependent Variable* trecem variabila *performanta*, iar în câmpul *Fixed Factor(s)* trecem variabilele *autonomie* și *internalism-externalism*. Activăm butonul *Options*, iar în câmpul *Display* bifăm opțiunile *Descriptive statistics*, *Estimates of effect size* și *Homogeneity tests*.

Univariate

Dependent Variable:
☒ performanta [perform]

Fixed Factor(s):
☒ internalism-externalism
☒ autonomie in invatare

Random Factor(s):

Covariate(s):

WLS Weight

Model...
 Contrasts...
 Plots...
 Post Hoc...
 Save...
 Options...

Univariate: Options

Estimated Marginal Means
 Factor(s) and Factor Interactions:
☒ (OVERALL)
☐ autonomie
☐ internalism

Display Means for:

Display:
☒ Descriptive statistics
☐ Estimates of effect size
☐ Observed power
☐ Parameter estimates
☐ Contrast coefficient matrix
☒ Homogeneity tests
☐ Spread vs. level plot
☐ Residual plot
☐ Lack of fit
☐ General estimable function

Significance level: .05 Confidence intervals are 95%

Continue Cancel Help

19.00	1	1	7.05	1.00
20.00	1	1	6.88	1.00
21.00	1	1	7.94	1.00

14.3. Interpretarea outputului

Tabelul *Descriptive statistics* prezintă mediile, deviațiile standard și numărul subiecților pentru fiecare dintre cele șase celule experimentale (C1-C6), precum și pentru fiecare nivel al fiecărei VI și pentru întregul lot experimental.

Descriptive Statistics

Dependent Variable: performanta

internalism-externalism	autonomie in invatare	Mean	Std. Deviation	N
internalisti	scazuta	7,8100	,7806	30
	medie	8,1323	,6250	30
	ridicata	8,8787	,7293	30
	Total	8,2737	,8377	90
externalisti	scazuta	8,7030	,7341	30
	medie	8,5040	,8753	30
	ridicata	8,1053	,7334	30
	Total	8,4374	,8142	90
Total	scazuta	8,2565	,8758	60
	medie	8,3182	,7770	60
	ridicata	8,4920	,8233	60
	Total	8,3556	,8278	180

Din tabelul *Levene's Test of Equality of Error Variance's* observăm că Levene $F(5, 174) = 0,648$, $p > 0,05$ ($p = 0,663$), prin urmare condiția de egalitate a varianțelor este îndeplinită.

Levene's Test of Equality of Error Variances^a

Dependent Variable: performanta

F	df1	df2	Sig.
,648	5	174	,663

Tests the null hypothesis that the error variance of the dependent variable is equal across groups.

a. Design: Intercept+IE+AUTONOM+IE * AUTONOM

În tabelul principal al tehnicii ANOVA factorială, *Tests of Between-Subjects Effects* (asemănător celui de la ANOVA simplă), pentru fiecare dintre sursele de varianță sunt afișate suma pătratelor (calculată prin metoda Type III), gradele de libertate (df), media pătrată (o măsură a varianței), valorile testelor F și pragurile de semnificație p (Sig.). Nota tabelului prezintă coeficienții R^2 și R^2 ajustat pentru modelul explicativ având la bază metoda regresiei. În calcularea testelor F s-a împărțit media pătrată pentru fiecare VI și interacțiunii la media pătrată a erorii. Vom urmări în tabel liniile corespunzătoare VI și interacțiunii. Constatăm că există un efect de interacțiune semnificativ, $F(2, 174) = 19,378$, $p = 0,000$ și nu există efecte principale semnificative [pentru *internalism-externalism*, $F(1, 174) = 2,146$, $p = 0,145$, iar pentru *autonomie* $F(2, 174) = 1,591$, $p = 0,207$].

Tests of Between-Subjects Effects

Dependent Variable: performanta

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	24,794 ^a	5	4,959	8,817	,000
Intercept	12566,756	1	12566,756	22343,369	,000
IE	1,207	1	1,207	2,146	,145
AUTONOM	1,790	2	,895	1,591	,207
IE * AUTONOM	21,797	2	10,899	19,378	,000
Error	97,864	174	,562		
Total	12689,414	180			
Corrected Total	122,658	179			

a. R Squared = ,202 (Adjusted R Squared = ,179)

În continuare se vor analiza efectele principale și efectul de interacțiune atunci când acestea sunt semnificative statistic.

14.4. Analiza efectelor principale


Interpretarea efectelor principale se face la fel ca în ANOVA simplă. Atunci când un test F corespunzător unui efect principal din tabelul 14.4 este semnificativ, acesta ne spune

doar că există diferențe semnificative între grupuri, însă nu știm între care grupuri și în ce sens sunt aceste diferențe. Pentru a le afla se impune aplicarea testelor de contrast sau a testelor post hoc la fel ca în ANOVA simplă. Mediile grupurilor comparate se regăsesc în tabelul *Descriptive*. Cum în cazul nostru cele două efecte principale nu sunt semnificative, nu vom proceda la aplicarea testelor de contrast sau post hoc. Prezentăm în continuare rezultatele.

Nu există un efect principal semnificativ al *autonomiei* asupra *performanței*, ignorând *internalismul-externalismul* subiecților, $F(2, 174) = 1,59, p > 0,05$.

Nu există un efect principal semnificativ al variabilei *internalism-externalism* asupra *performanței*, ignorând *autonomia în învățare*, $F(1, 174) = 2,15, p > 0,05$.

Reprezentarea grafică a unui efect principal semnificativ se face activând butonul *Plots*, trecând variabila respectivă în câmpul *Horizontal Axis*, clic pe butonul *Add*, clic *Continue* și *OK*. Reprezentarea grafică a diferențelor între grupuri poate fi și sub formă de bare (*Graphs* → *Bar* etc.).



Mărima efectului în cazul efectelor principale se calculează ca în ANOVA simplă, pe baza formulelor (13.5) și (13.6).


14.5. Analiza efectelor de interacțiune

Atunci când efectele de interacțiune nu sunt semnificative, analiza noastră se reduce de obicei¹ la interpretarea efectelor principale. *Dacă însă un efect de interacțiune este semnificativ, ne vom concentra asupra interpretării acestuia.* În cazul de față, există un

1. Vom reveni asupra acestui aspect în finalul prezentării tehnicii ANOVA factoriale.

efect de interacțiune semnificativ, $F(2, 174) = 19,378$, $p < 0,001$, în sensul că gradul de autonomie influențează performanța în mod diferit pentru internaliști și externaliști (rămâne să vedem și în ce sens). Reprezentarea grafică a interacțiunii se face activând butonul *Plots*, trecând variabila *autonomie* în câmpul *Horizontal Axis*, iar variabila *internalism-externalism* în câmpul *Separate Lines*, clic pe butonul *Add*, apoi clic *Continue* și *OK*. Graficul obținut este prezentat de mai jos. O altă reprezentare grafică a efectului de interacțiune poate fi făcută prin intermediul barelor.

Există două direcții generale de analiză a efectelor de interacțiune: 1) analiza efectelor simple și 2) analiza contrastelor de interacțiune (Keppel, 1991, *apud* Page, Braver și MacKinnon, 2003).



14.6. Analiza efectului de interacțiune prin intermediul efectelor simple

Prin acest demers analizăm influența unei VI în fiecare dintre condițiile altei VI. În designul experimental analizat, 3×2 , avem șase grupe experimentale (G1-G6) și șase medii corespunzătoare fiecărui grup experimental (M1-M6). Vom avea două posibilități de analiză:

- analiza efectelor simple ale VI *autonomie* în fiecare dintre cele două condiții ale VI *internalism-externalism* (două efecte simple ale VI *autonomie*):
 1. efectul simplu al autonomiei în condiție de internalism (verificăm dacă există diferențe semnificative între mediile M1, M3 și M5),
 2. efectul simplu al autonomiei în condiție de externalism (comparam mediile M2, M4 și M6);
- analiza efectelor simple ale VI *internalism-externalism* în cele trei condiții ale VI *autonomie* (trei efecte simple ale VI *internalism-externalism*):

1. efectul simplu al internalismului-externalismului în condiție de autonomie scăzută (comparăm mediile M1 și M2),
2. efectul simplu al internalismului-externalismului în condiție de autonomie medie (comparăm mediile M3 și M4),
3. efectul simplu al internalismului-externalismului în condiție de autonomie ridicată (comparăm mediile M5 și M6).

Se recomandă analiza efectelor simple corespunzătoare doar uneia dintre VI, și nu ambelor VI, deoarece informațiile obținute ar fi redundante.

Observăm că în efectele simple descrise mai sus am comparat mediile fie pe linie (în cazul efectului simplu al autonomiei), fie pe coloane (în cazul efectului simplu al internalismului-externalismului). Însă, în funcție de scopul studiului nostru, vom putea compara mediile și pe diagonală (de exemplu, dacă există diferențe semnificative între M1 și M4 sau între M1 și M6 etc.).

Cum analizăm efectele simple? Există mai multe tehnici:


1. prin împărțirea bazei de date (comanda *Split File*);
2. prin crearea unei noi variabile;
3. prin folosirea sintaxelor (Page, Braver și MacKinnon, 2003) și
4. prin utilizarea unor formule matematice (Sava, 2004).

Tehnicile 3 și 4 sunt cele mai puternice, deoarece evită erorile de tipurile I și II. Vom prezenta în continuare doar primele trei tehnici.


14.6.1. Analiza efectelor simple prin împărțirea bazei de date (*Split File*)

Analiza efectelor simple ale primei VI presupune mai întâi împărțirea bazei de date în funcție de nivelele celeilalte (celorlalte) VI și aplicarea testelor de comparare a mediilor între nivelele primei VI. Pentru analiza efectelor simple ale celeilalte (celorlalte) VI se procedează analog. Să exemplificăm.


Analiza efectelor simple ale variabilei *internalism-externalism*
Deschidem meniul *Data* → *Split File*.



Activăm opțiunea *Organize output by groups*, în câmpul *Groups Based on* trecem variabila *autonomie*, apoi clic OK.



Acum orice analiză va fi realizată pentru fiecare dintre nivelele variabilei *autonomie*. Analizăm în continuare diferențele dintre internaliști și externaliști prin teste t pentru eșantioane independente. În meniul *Analyze* → *Compare Means* → *Independent-Samples T Test* trecem variabila *performanta* în câmpul *Test Variable(s)*, apoi trecem variabila *internalism-externalism* în câmpul *Grouping Variable* și prin activarea butonului *Define Groups* definim grupurile acestei variabile cu „1” și „2”.



Efectul simplu al variabilei *internalism-externalism* în condiție de *autonomie scăzută* este semnificativ; există diferențe semnificative între G1 și G2 [$t(58) = 4.565$, $p = 0,000$] (tabelul *Independent Samples Test 1*). Astfel, în condiție de *autonomie scăzută*, externaliștii obțin performanțe superioare internaliștilor.

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means				
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference
performanta	Equal variances assumed	,192	,663	-4,565	58	,000	-,8930	,1956
	Equal variances not assumed			-4,565	57,78			

a. autonomie in invatare = scazuta

Efectul simplu al variabilei *internalism-externalism* în condiție de *autonomie medie* este nesemnificativ ; nu există diferențe semnificative între G3 și G4 [$t(58) = 1,893$, $p = 0,063$] (tabelul *Independent Samples Test 2*).

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means				
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference
performanta	Equal variances assumed	2,427	,125	-1,893	58	,063	-,3717	,1964
	Equal variances not assumed			-1,893	52,468			

a. autonomie in invatare = medie

Efectul simplu al variabilei *internalism-externalism* în condiție de *autonomie ridicată* este semnificativ ; există diferențe semnificative între G5 și G6 [$t(58) = 4,095$, $p = 0,000$] (tabelul *Independent Samples Test 3*). Prin urmare, în condiție de autonomie ridicată, internaliștii obțin performanțe superioare externaliștilor.

Independent Samples Test


		Levene's Test for Equality of Variances		t-test for Equality of Means				
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference
performanta	Equal variances assumed	,041	,840	4,095	58	,000	,7733	,1888
	Equal variances not assumed			4,095	57,998			

a. autonomie in invatare = ridicata


Analiza efectelor simple ale variabilei *autonomie* se face similar.

Până în acest moment știm cum să comparăm grupurile fie pe verticală, fie pe orizontală. Să vedem *cum comparăm grupurile pe diagonală*; considerăm grupurile G4 (externalism și autonomie medie) și G5 (internalism și autonomie ridicată). Revenim în meniul *Data* → *Split File*, clic pe butonul *Reset* și clic *OK* (astfel am anulat comenzile anterioare din acest meniu).

Activăm meniul *Data* → *Select Cases*.



Aici selectăm opțiunea *If condition is satisfied*; apoi clic pe butonul *If*.



În câmpul din dreapta definim grupurile pe care le dorim selectate din toată baza de date. În cazul nostru, trecem (*ie = 2 & autonom = 2*) + (*ie = 1 & autonom = 3*), mai exact parametrii definitorii ai fiecărui grup în paranteză.

Select Cases: If

☒ nrsb
☒ internalism-externalism
☒ autonomie in invatare []
☒ performanta [perform]
☒ sase grupe experiment

(ie = 2 & autonom = 2) + (ie = 1 & autonom = 3)

+ < > 7 8 9
 - <= >= 4 5 6
 * = ~= 1 2 3
 / & | 0 .
 ** ~ () Delete

Functions:

ABS(numexpr)
 ANY(test,value,value,...)
 ARSIN(numexpr)
 ARTAN(numexpr)
 CDFNORM(zvalue)
 CDF.BERNOULLI(q,p)

Continue Cancel Help

Mai departe aplicăm testul t pentru eșantioane independente, în care VI va fi *internalism-externalism* cu cele două nivele „1” și „2” sau *autonomie* cu cele două nivele în cazul comparației de față, „2” și „3”. Rezultatele prezentate în tabelul *Independent Samples Test* de mai jos arată că nu există diferențe semnificative între G4 și G5 [$t(58) = 1,801$, $p = 0,077$].


Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means				
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference
performanta	Equal variances assumed	,209	,649	1,801	58	,077	,3747	,2080
	Equal variances not assumed			1,801	56,169	,077	,3747	,2080


14.6.2. Analiza efectelor simple prin crearea unei noi variabile

Logica acestei analize presupune crearea unei noi variabile care să conțină atâtea nivele câte grupe experimentale conține designul ANOVA și ulterior aplicarea testelor de contrast pentru compararea grupelor care ne interesează. Această tehnică, deși aparent puțin mai complicată decât prima, este foarte eficientă pentru designurile cu mai mult de două VI. În exemplul nostru, pentru un design 3×2 avem 6 grupe experimentale, deci variabila nou creată va avea șase categorii (pentru un design 2×2 , noua variabilă va avea patru categorii etc.). Vom șterge mai întâi variabila *grupexp* existentă în baza de date pentru a o crea din nou urmând pașii detaliați în continuare.


Deschidem meniul *Transform* → *Compute*.



În câmpul *Target Variable* definim noua variabilă pe care o vom numi *grupexp*, apoi click pe butonul *Type and Label*, iar în câmpul *Label* trecem șase grupe experimentale ; clic *Continue*.



În câmpul *Numeric Expression* trecem valoarea „1” care va fi codul pentru primul grup. Apoi, activăm butonul *If*, selectăm opțiunea *Include if case satisfies condition*, iar în câmpul activat scriem $(autonom = 1) \& (ie = 1)$, clic *Continue*, clic *OK*.




În baza de date am creat o nouă variabilă, *grupexp*, care la nivelul 1 combină primul nivel al *autonom* (1) cu primul nivel al *ie* (1) și corespunde primului grup experimental din design (G1).

Reluăm procedeul pentru a crea și celelalte cinci nivele ale noii variabile *grupexp*. Selectăm *Transform* → *Compute*, ne asigurăm că *grupexp* este în câmpul *Target Variable*, în câmpul *Numeric Expression* trecem valoarea 2 care va fi codul pentru G2. Activăm butonul *If*, ne asigurăm că este selectată opțiunea *Include if case satisfies condition*, iar în câmpul activat scriem (*autonom* = 1) & (*ie* = 2), clic *Continue*, clic *OK*. Va apărea un mesaj de avertisment al SPSS care solicită confirmarea că se schimbă variabila existentă: clic *OK*! Tocmai am adăugat nivelul 2 la variabila *grupexp*, care corespunde grupului G2 din design.

Repetăm pașii pentru crearea celorlalte nivele ale variabilei *grupexp*, astfel: nivelul 3 al *grupexp* - *autonom* = 2 & *ie* = 1; nivelul 4 *grupexp* - *autonom* = 2 & *ie* = 2; nivelul 5 *grupexp* - *autonom* = 3 & *ie* = 1; nivelul 6 *grupexp* - *autonom* = 3 & *ie* = 2.

Știm că nivelele variabilei *grupexp* corespund în ordine grupelor experimentale G1-G6 din design. Așadar, în baza de date vom defini nivelele variabilei *grupexp* astfel: 1 = G1; 2 = G2; 3 = G3; 4 = G4; 5 = G5; 6 = G6.



Mai departe vom analiza fiecare efect simplu cu ajutorul testelor de contrast sau prin teste post hoc. Sunt recomandate testele de contrast, acestea fiind mai puternice.

Deschidem meniul *Analyze* → *Compare Means* → *One-Way ANOVA*, trecem *performanța* în câmpul *Dependent List*, *grupexp* în câmpul *Factor*, iar în *Options* activăm *Homogeneity of variance test*.

Vom analiza efectele simple ale variabilei *internalism-externalism* prin teste de contrast, comparând grupurile G₁-G₂, G₃-G₄ și G₅-G₆. Coeficienții de contrast vor fi (1,-1,0,0,0,0), (0,0,1,-1,0,0) și (0,0,0,0,1,-1), iar setul de contraste este ortogonal.

Contrast Tests

		Contrast	Value of Contrast	Std. Error	t	df	Sig. (2-tailed)
performanța	Assume equal variances	1	-.8930	.1936	-4.612	174	.000
		2	-.3717	.1936	-1.919	174	.057
		3	.7733	.1936	3.994	174	.000
	Does not assume equal variances	1	-.8930	.1956	-4.565	57.782	.000
		2	-.3717	.1964	-1.893	52.468	.064
		3	.7733	.1888	4.095	57.998	.000


Din tabelul *Contrast Tests* constatăm că doar contrastele 1 și 3 sunt semnificative. Astfel, există diferențe semnificative între G_1-G_2 [$t(174) = 4,612, p = 0,000$], între G_5-G_6 [$t(174) = 3,994, p = 0,000$] și nu există diferențe semnificative între G_3-G_4 [$t(174) = 1,919, p = 0,057$]. Rezultatele sunt conforme cu cele obținute prin metoda împărțirii bazei de date (Split File).

Putem realiza și comparații ale grupurilor pe diagonală. În cazul nostru ne-ar interesa să comparăm G_5 cu G_4 pentru a vedea dacă internaliștii cu *autonomie ridicată* obțin performanțe semnificativ mai mari comparativ cu *externaliștii* cu *autonomie medie*. Coeficienții de contrast sunt (0001–10). Vom constata că nu există diferențe semnificative.

14.6.3. Analiza efectelor simple prin folosirea sintaxelor

În sintaxele pe care le vom utiliza vom aplica comanda MANOVA, și nu UNIANOVA sau GLM (specifice metodei ANOVA factorială), deoarece analiza efectelor simple în UNIANOVA este mult mai complexă decât în MANOVA. Deși metoda MANOVA poate realiza analize multivariate (analize cu două sau mai multe VD), ea poate de asemenea realiza și analize univariate (analize cu o singură VD) – cu ajutorul sintaxelor.

Deschidem meniul *File* → *New* → *Syntax*.



În fereastra deschisă vom scrie „MANOVA”, variabila dependentă „perform”, apoi cuvântul „BY” care va fi urmat de numele VI. Fiecare VI va fi urmată de un set de paranteze care conține informații despre categoriile sale. Pentru o VI cu două categorii vom trece (1,2), pentru una cu trei categorii (1,3) etc. Următoarele rânduri vor începe fiecare cu „/”. Așadar, pe rândul 2 scriem „/”, urmat imediat de „ERROR=WITHIN”. Pe rândul 3 tastăm „/” urmat de „DESIGN=”, după care vom specifica efectele simple urmărite.


Să analizăm efectele simple ale VI *internalism-externalism* (IE) în cele trei condiții ale VI *autonomie* (scăzută, medie și ridicată). Aceste efecte simple vor fi trecute astfel: „ie WITHIN autonom(1), ie WITHIN autonom(2), ie WITHIN autonom(3)”. Am specificat astfel că vrem să analizăm efectele simple ale variabilei IE în condițiile de autonomie scăzută [autonom(1)], autonomie medie [autonom(2)] și autonomie ridicată [autonom(3)]. Încheiem fiecare sintaxă cu un punct. Prezentăm mai jos sintaxa pentru analiza efectelor simple ale variabilei independente IE:

```
MANOVA perform BY autonom(1,3) ie(1,2)
```

```
/ERROR=WITHIN
```

```
/DESIGN=ie WITHIN autonom(1), ie WITHIN autonom(2), ie WITHIN autonom(3).
```


Fixăm apoi cursorul la sfârșitul sintaxei, după punct, și facem clic pe butonul **Run** , sau activăm meniul **Run** → **To End** pentru a aplica metodele specificate în sintaxă.



Rezultatele sunt prezentate mai jos.

Source of Variation	SS	DF	MS	F	Sig of F
WITHIN CELLS	97.86	174	.56		
IE WITHIN AUTONOM(1)	11.96	1	11.96	21.27	.000
IE WITHIN AUTONOM(2)	2.07	1	2.07	3.68	.057
IE WITHIN AUTONOM(3)	8.97	1	8.97	15.95	.000

Observăm că efectul simplu al VI *internalism-externalism* este semnificativ doar în condițiile de *autonomie scăzută* [$F(1, 174) = 21,27, p = 0,000$] și *autonomie ridicată* [$F(1, 174) = 15,95, p = 0,000$] și nesemnificativ în condiție de *autonomie medie* [$F(1, 174) = 3,68, p = 0,057$]. Prin urmare, există diferențe semnificative în ceea ce privește performanța între internaliști și externaliști, în condițiile de autonomie scăzută și ridicată. Rezultatele sunt conforme celor obținute în cadrul metodelor anterioare (metoda Split File și metoda creării unei noi variabile).

Vom calcula mărimea efectelor aplicând formula :

$$r = \sqrt{\frac{F_{\text{contrast}}}{F(df_{\text{intergrup}}) + df_{\text{intragrup}}}} = \sqrt{\frac{t^2_{\text{contrast}}}{F(df_{\text{intergrup}}) + df_{\text{intragrup}}}}$$


$$r_{IE(\text{Autonomie} \text{ - } \text{Scăzută})} = \sqrt{\frac{21,27}{19,38 \cdot 2 + 174}} = 0,32$$

$$r_{IE(\text{Autonomie} \text{ - } \text{Medie})} = \sqrt{\frac{3,68}{19,38 \cdot 2 + 174}} = 0,13$$

$$r_{IE(\text{Autonomie} \text{ - } \text{Ridicată})} = \sqrt{\frac{15,95}{19,38 \cdot 2 + 174}} = 0,27$$

Să analizăm, pentru exemplificare, și efectele simple ale VI *autonomie* în cele două condiții ale *internalismului-externalismului*. Acestea vor fi menționate astfel : „autonom WITHIN ie(1), autonom WITHIN ie(2)”. Am specificat astfel că vrem să analizăm efectul simplu al VI *autonomie* atât în condiția de internalism [ie(1)], cât și în condiția de externalism [ie(2)]. Sintaxa va fi :

```
MANOVA perform BY autonom(1,3) ie(1,2)
/ERROR=WITHIN
/DESIGN=autonom WITHIN ie(1), autonom WITHIN ie(2).
```




Rezultatele din output vor fi următoarele :

Source of Variation	SS	DF	MS	F	Sig of F
WITHIN CELLS	97.86	174	.56		
AUTONOM WITHIN IE (1)	18.03	2	9.01	16.03	.000
AUTONOM WITHIN IE (2)	5.56	2	2.78	4.94	.008

Constatăm că efectul simplu al variabilei *autonomie* în condiție de internalism este semnificativ, $F(2, 174) = 16,03$, $p = 0,000$ și de asemenea efectul simplu al variabilei *autonomie* în condiție de externalism este semnificativ, $F(2, 174) = 4,94$, $p = 0,008$. Știm astfel că, în cazul subiecților internaliști, există diferențe semnificative între cele trei grupuri (cei care beneficiază de autonomie ridicată, medie și scăzută) însă nu știm și între care grupuri sunt semnificative aceste diferențe. Același lucru este valabil și în cazul subiecților externaliști. Suntem în situația analoagă variantei cu împărțirea bazei de date în care am fi aplicat *Split File* după VI *internalism-externalism* și One-Way ANOVA după VI *autonomie*, având doar rezultatul la testul ANOVA F omnibus ; urmează aplicarea testelor de contrast sau post hoc.

Vom aplica teste de contrast pentru a compara categoriile *autonomie scăzută* cu *autonomie ridicată* și *autonomie medie* cu *autonomie ridicată*, în condiția de *internalism*. Sintaxa va fi următoarea :

```
MANOVA perform BY autonom(1,3) ie(1,2)
/ERROR=WITHIN
/CONTRAST(autonom)=SPECIAL (1 1 1, 1 0 -1, 0 1 -1)
/DESIGN=autonom(1) WITHIN ie(1), autonom(2) WITHIN ie(1).
```



Elementele noi în această sintaxă apar pe rândul al treilea. Subcomanda „CONTRAST” este urmată de numele variabilei asupra căreia realizăm contrastul. După semnul de egalitate specificăm tipul de contrast pe care îl alegem (poate fi unul dintre contrastele standardizate – și atunci trecem numele contrastului respectiv – sau putem alege un contrast nestandardizat, definit de noi, și în acest caz vorbim despre un contrast „SPECIAL”)¹.

Contrastele nestandardizate „SPECIAL” pot fi ortogonale sau nonortogonale. Numărul de contraste speciale care trebuie specificate este $(k - 1)$, unde k este numărul de grupuri. Dacă vrem să analizăm mai puțin de $(k - 1)$ contraste, vom trece contrastele care ne interesează și vom adăuga altele (pe care le vom ignora în analiză) până obținem $(k - 1)$ contraste. Dacă însă vrem să analizăm mai mult de $(k - 1)$ contraste, vom repeta subcomenzile „CONTRAST” și „DESIGN”, operând substituirile necesare.

După „SPECIAL” scriem între paranteze un set de coeficienți; numărul total al coeficienților trebuie să fie egal cu pătratul numărului de categorii ale VI respective. Pentru o VI cu două categorii vom trece patru coeficienți, pentru o VI cu trei categorii vom trece nouă coeficienți etc. În prima grupare, toți coeficienții sunt „1” (reprezintă efectul principal al VI respective, care este în general ignorat). Următoarele două grupări de coeficienți corespund celor două contraste pe care le realizăm. Ultima linie a sintaxei este aproape neschimbată, doar că variabila „autonom” este urmată mai întâi de „(1)” și apoi de „(2)”², cifre care vor indica în output numărul contrastului realizat (primul, al doilea etc.). Rezultatele relevante sunt prezentate în continuare.


1. Lucrurile sunt puțin diferite în cazul contrastelor SIMPLE și DEVIATION, în cazul cărora trebuie specificată între paranteze categoria de referință; în caz contrar, ultima categorie va fi considerată ca referință. Pentru SIMPLE(1) toate grupele vor fi comparate cu prima, pentru SIMPLE(2) toate grupele sunt comparate cu a doua etc. Așadar, prin sintaxe, numărul de contraste standardizate posibile se mărește.
2. Regula de construcție a sintaxei pentru contraste presupune ca variabila asupra căreia se face contrastul să fie urmată în paranteză de cifrele „1”, „2”, „3” etc., cu o unitate mai puțin decât nivelele variabilei respective; pentru o VI „factor” cu 4 nivele vom scrie: „factor(1), factor(2), factor(3)”.

Tests of Significance for PERFORM using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN CELLS	97.86	174	.56		
AUTONOM(1) WITHIN IE(1)	17.13	1	17.13	30.46	.000
AUTONOM(2) WITHIN IE(1)	8.36	1	8.36	14.86	.000

Deoarece am aplicat două teste de contrast neortogonale, pragul de semnificație va fi ajustat, $p \leq 0,025$ ($= 0,05/2$). Observăm că primul contrast [AUTONOM(1)] este semnificativ în condiție de internalism [WITHIN IE(1)], $F(1, 174) = 30,46$, $p = 0,000$, prin urmare în cazul internaliștilor există diferențe semnificative între grupurile *autonomie scăzută* și *autonomie ridicată*. De asemenea, și al doilea contrast [AUTONOM(2)] este semnificativ în condiție de internalism, $F(1, 174) = 14,86$, $p = 0,000$, existând diferențe semnificative între grupurile *autonomie medie* și *autonomie ridicată* (sensul diferențelor pot fi observate din grafic).

Verificăm acum existența diferențelor semnificative între grupurile *autonomie scăzută* și *autonomie ridicată* și, de asemenea, *autonomie medie* și *autonomie ridicată*, în condiție de *externalism*. Aplicăm tot teste de contrast, iar sintaxa va fi următoarea:

```
MANOVA perform BY autonom(1,3) ie(1,2)
/ERROR=WITHIN
/CONTRAST(autonom)=SPECIAL (1 1 1, 1 0 -1, 0 1 -1)
/DESIGN=autonom(1) WITHIN ie(2), autonom(2) WITHIN ie(2).
```



Rezultatele relevante sunt prezentate în continuare, iar interpretarea este similară condiției de *internalism*. Observăm că doar primul contrast este semnificativ. Prin urmare, în condiție de *externalism*, există diferențe semnificative la pragul $p \leq 0,025$ (ajustat) între grupurile *autonomie scăzută* și *autonomie ridicată*, $F(1, 174) = 9,53$, $p < 0,025$ și nu există diferențe semnificative între grupurile *autonomie medie* și *autonomie ridicată*, $F(1, 174) = 4,24$, $p > 0,025$.

Tests of Significance for PERFORM using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN CELLS	97.86	174	.56		
AUTONOM(1) WITHIN IE(2)	5.36	1	5.36	9.53	.002
AUTONOM(2) WITHIN IE(2)	2.38	1	2.38	4.24	.041

14.7. Prezentarea rezultatelor

Pentru a analiza efectul variabilelor *autonomie* și *internalism-externalism* asupra variabilei *performanță* am aplicat metoda analizei de varianță ANOVA factorială. Conform rezultatelor obținute, nu există un efect principal semnificativ al variabilei *internalism-externalism* asupra variabilei *performanță* și de asemenea nu există un efect principal semnificativ al variabilei *autonomie* asupra variabilei *performanță*. În schimb, există un efect de interacțiune semnificativ statistic al variabilelor *internalism-externalism* și *autonomie* asupra variabilei *performanță* (tabelul 14.2). Tabelul 14.3 prezintă mediile, abaterile standard și numărul de subiecți în ceea ce privește variabila *performanță* pentru fiecare condiție experimentală, pentru fiecare nivel al variabilelor independente, precum și per total.

Tabelul 14.2. Tabelul ANOVA factorială pentru *performanță* în funcție de *autonomie* și *internalism-externalism*

Variabile și sursa dispersie	SS	df	MS	F	p
IE	1,21	1	1,21	2,15	0,145
Autonomie (A)	1,79	2	0,90	1,59	0,207
IE × A	21,80	2	10,90	19,38	0,000
Internalism-externalism					
Autonomie scăzută	11,96	1	11,96	21,27	0,000
Autonomie medie	2,07	1	2,07	3,68	0,057
Autonomie ridicată	8,97	1	8,97	15,95	0,000
Eroare (intragrup)	97,86	174	0,6		
Totală	12689,41	180			

Tabel 14.3. Mediile, deviațiile standard și loturile de subiecți pentru *performanță* în funcție de *autonomie* și *internalism-externalism*

	Internaliști			Externaliști			Total		
	M	SD	n	M	SD	n	M	SD	n
Autonomie									
Scăzută	7,81	0,78	30	8,70	0,73	30	8,26	0,87	60
Medie	8,13	0,62	30	8,50	0,87	30	8,32	0,78	60
Ridică	8,88	0,73	30	8,10	0,73	30	8,49	0,82	60
Total	8,27	0,84	90	8,44	0,81	90	8,35	0,83	180

Analizând efectele simple ale variabilei internalism-externalism observăm că acestea sunt semnificative statistic doar în condiția de autonomie scăzută [$F(1, 174) = 21,27$, $p = 0,000$, $r = 0,32$] și *autonomie ridicată* [$F(1, 174) = 15,95$, $p = 0,000$, $r = 0,27$], nu și în condiție de *autonomie medie* [$F(1, 174) = 3,68$, $p = 0,057$, $r = 0,27$]. Prin urmare, există diferențe semnificative în ceea ce privește performanța între internaliști și externaliști, în condiția de autonomie scăzută, subiecții internaliști obțin performanțe mai mici comparativ cu cei externaliști (mărima efectului fiind moderată $r = 0,32$), iar în condiția de autonomie ridicată subiecții internaliști obțin performanțe mai mari comparativ cu cei externaliști (mărima efectului fiind moderată, $r = 0,27$).

Observație. Atunci când efectele simple sunt calculate prin teste t pentru eșantioane independente, valorile corespunzătoare F care vor fi trecute în tabelul 14.2 sunt calculate pe baza formulei $F = t^2$.

14.8. Analiza efectului de interacțiune prin intermediul contrastelor de interacțiune

14.8.1. Prezentare generală


Așa cum spuneam anterior, contrastele de interacțiune pot fi analizate doar prin tehnica sintaxelor. Să presupunem că avem două variabile independente, A și B . Acest tip de analiză studiază dacă un contrast (compararea a două medii) al variabilei A acționează diferit într-un nivel al variabilei B comparativ cu un alt nivel al variabilei B (Page, Braver și MacKinnon, 2003).

Dacă prin efectele simple *verificăm efectul* unei VI în diferite condiții ale altei VI , prin contraste de interacțiune *comparăm efectele* unei VI în diferite condiții ale altei VI . Altfel spus, contrastele de interacțiune urmăresc să compare amplitudinea unor efecte simple, și nu doar simpla existență a acestora.

Considerăm un design 2×2 în care variabilele independente sunt A (training inteligență emoțională, două categorii: fără training sau grup de control, cu training) și B (gen, două categorii: masculin, feminin), iar variabila dependentă este inteligența emoțională.

Tabel 14.5. Design 2×2

		A (training)	
		Fără training grup de control	Cu training grup experimental
B (gen)	Masculin	M1	M2
	Feminin	M3	M4



Până acum, prin intermediul efectelor simple puteam verifica dacă oricare două diferențe dintre medii (de exemplu, $M2 - M1$) este semnificativă statistic. În acest moment, prin intermediul contrastelor de interacțiune vom putea compara dacă $M2 - M1 \neq M4 - M3$, iar această diferență este semnificativă. Din graficul de mai sus se vede clar că efectul trainingului este mai mare în cazul băieților decât în cazul fetelor (chiar dacă în ambele cazuri conduce la o dezvoltare a inteligenței emoționale) și asta doar comparând unghiurile dintre axa OX și dreptele corespunzătoare celor două genuri: în cazul băieților unghiul este de peste 45° în vreme ce în cazul fetelor unghiul este de sub 30° . Așadar, este clar că efectul este mai puternic în cazul băieților decât în cazul fetelor. Ei bine, prin contraste de interacțiune analizăm dacă efectul în cazul băieților este *semnificativ mai mare* decât efectul în cazul fetelor.

De regulă, contrastele de interacțiune sunt specificate a priori. Rezultatele sunt similare comparării mărimii efectelor în cazul efectelor simple, doar că aici dispunem și de un test statistic¹.

Exemplu. Atunci când evaluăm două metode de predare, dorim să verificăm dacă metoda 1 are un efect semnificativ mai puternic asupra performanței elevilor de liceu, comparativ cu elevii de gimnaziu.

1. Există tehnici statistice de comparare a semnificației diferențelor dintre doi coeficienți de corelație (ceea ce până la urmă este indicatorul r al mărimii efectului), însă nu fac obiectul materialului de față.

14.8.2. Analiza contrastelor de interacțiune

Presupunem că ne interesează să analizăm efectul variabilei gen și al tipului de training în statistică asupra rezultatelor obținute de studenți la examenul de statistică. Variabila dependentă este *performanța* (rezultatul la examen). Variabilele independente sunt *genul* subiecților (două categorii : masculin, feminin) și *tipul de training* (trei categorii : fără training sau grup de control, 3 ore de training, 6 ore de training). Designul cercetării este de tipul 2×3 .

Tabelul 14.6. Designul cercetării 2×3

		Gen	
		masculin	feminin
Training	grup de control	G1 (M1)	G2 (M2)
	3 ore	G3 (M3)	G4 (M4)
	6 ore	G5 (M5)	G6 (M6)

Vom analiza dacă cele două tipuri de training conduc la performanțe diferite în cazul fetelor, comparativ cu băieții. Mai întâi, vom verifica dacă trainingul de 3 ore are efect mai puternic asupra băieților, comparativ cu fetele (comparăm diferența $M3 - M1$ cu diferența $M4 - M2$). Apoi, vom verifica dacă efectul trainingului de 6 ore este mai puternic în cazul băieților decât în cazul fetelor (vom compara diferența $M5 - M1$ cu diferența $M2 - M6$).

Deschidem fișierul *training_statistica*. Analizăm dacă există o influență a variabilelor *gen* și *training* asupra variabilei *performanță* prin intermediul tehnicii ANOVA factorială așa cum am văzut anterior.

În tabelul *Descriptive Statistics* sunt prezentate mediile, abaterile standard și numărul de subiecți pentru fiecare celulă experimentală, pentru nivelul fiecărei variabile independente, precum și per total.

Descriptive Statistics

Dependent Variable: performanta test

genul subiecților	tipul de training	Mean	Std. Deviation	N
masculin	grup de control	7,8100	,78060	30
	training 3 ore	8,1323	,62497	30
	training 6 ore	9,0400	,58129	30
	Total	8,3274	,84271	90
feminin	grup de control	8,1053	,73336	30
	training 3 ore	8,5040	,87533	30
	training 6 ore	8,7030	,73406	30
	Total	8,4374	,81420	90
Total	grup de control	7,9577	,76552	60
	training 3 ore	8,3182	,77699	60
	training 6 ore	8,8715	,67810	60
	Total	8,3824	,82810	180

Urmărind rezultatele din tabelul *Tests of Between-Subjects Effects* observăm că nu există un efect principal al variabilei *gen* asupra variabilei *performanță* [(F (1, 174) = 1,027, p = 0,312], în schimb există un efect principal al variabilei *training* asupra variabilei *performanță* [(F (2, 174) = 23,980, p = 0,000]. De asemenea, există un efect de interacțiune al variabilelor *gen* și *training* asupra variabilei *performanță* [(F (2, 174) = 4,282, p = 0,015]. Vom analiza în continuare efectul de interacțiune prin intermediul contrastelor de interacțiune.

Tests of Between-Subjects Effects


Dependent Variable: performanta test

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	30,508 ^a	5	6,102	11,510	,000
Intercept	12647,767	1	12647,767	23858,478	,000
GEN	,544	1	,544	1,027	,312
TRAINING	25,425	2	12,712	23,980	,000
GEN * TRAINING	4,539	2	2,270	4,282	,015
Error	92,240	174	,530		
Total	12770,516	180			
Corrected Total	122,749	179			

a. R Squared = ,249 (Adjusted R Squared = ,227)

Prezentăm mai jos o ilustrare grafică a efectului de interacțiune.


Estimated Marginal Means of performanta test



Verificăm mai întâi dacă trainingul de 3 ore are un efect mai puternic asupra performanței în cazul băieților decât în cazul fetelor (comparăm diferența $M3 - M1$ cu diferența $M4 - M2$). Apoi, vom verifica dacă efectul trainingului de 6 ore este mai puternic în cazul băieților decât în cazul fetelor (vom compara diferența $M5 - M1$ cu diferența $M2 - M6$).

Vom analiza așadar două contraste de interacțiune – *training 3 ore versus grup de control* și *training 6 ore versus grup de control* în cele două condiții ale variabilei gen –, iar sintaxa este următoarea:

```
MANOVA perf BY training(1,3) gen(1,2)
/ERROR=WITHIN
/CONTRAST(training)=SPECIAL (1 1 1, 1 -1 0, 1 0 -1)
/DESIGN= training(1) BY gen, training(2) BY gen.
```



Dacă pe rândul al treilea am specificat cele două contraste ale variabilei independente *training*, pe rândul al patrulea am specificat cele două contraste de interacțiune. Numărul din paranteză, de după „training” se referă la contrastul care este testat, iar „BY gen” indică faptul că se va analiza dacă acest contrast se manifestă diferit în condiții distincte ale variabilei *gen*. Dacă variabila gen ar fi avut mai mult de două nivele lucrurile s-ar fi complicat puțin (vom discuta în continuare). Rezultatele relevante sunt următoarele:

Tests of Significance for PERF using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN CELLS	92,24	174	,53		
TRAINING(1) BY GEN	,04	1	,04	,08	,774
TRAINING(2) BY GEN	3,00	1	3,00	5,66	,018

Observăm că primul contrast de interacțiune este nesemnificativ, $F(1, 174) = 0,08$, $p = 0,774$. Cum „training(1)” compară efectul trainingului de 3 ore în cazul băieților cu efectul training-ului de 3 ore în cazul fetelor ($M3 - M1 = 8,13 - 7,81 = 0,33$ cu $M4 - M2 = 8,50 - 8,10 = 0,40$, adică 0,3 cu 0,4, vezi mediile din tabelul *Descriptive Statistics*) rezultă că trainingul de 3 ore are efecte relativ similare asupra performanței băieților și a fetelor.

Al doilea contrast de interacțiune este semnificativ, $F(1, 174) = 5,66$, $p = 0,018$ și cum „training(2)” compară efectul trainingului de 6 ore în cazul băieților cu efectul trainingului de 6 ore în cazul fetelor (compară $M5 - M1 = 9,04 - 7,81 = 1,23$ cu $M6 - M2 = 8,70 - 8,10 = 0,60$, adică $1,23$ cu $0,60$) rezultă că trainingul de 6 ore influențează performanța semnificativ mai mult în cazul băieților decât în cel al fetelor.

Mărimea efectului se calculează prin formula :

$$r = \sqrt{\frac{F_{\text{contrast}}}{F(df_{\text{int ergrup}}) + df_{\text{int ragrup}}}} = \sqrt{\frac{t^2_{\text{contrast}}}{F(df_{\text{int ergrup}}) + df_{\text{int ragrup}}}}$$

14.8.3. Contrastele de interacțiune când ambele variabile au mai mult de două nivele

Să presupunem că avem un design 4×3 în care variabila A are 4 nivele, iar variabila B are 3 nivele (tabelul 14.7).

Tabel 14.7. Design 4×3

		Variabila A			
		a 1	a 2	a 3	a 4
Variabila B	b 1	M1	M4	M7	M10
	b 2	M2	M5	M8	M11
	b 3	M3	M6	M9	M12

Pentru contraste de interacțiune într-un astfel de desing va trebui să specificăm mai întâi tipurile de contraste avute în vedere în cazul fiecărei VI. Să presupunem că în cazul variabilei A dorim să comparăm condițiile a1 cu a3, apoi a2-a4 și a3-a4 (coeficienții de contrast vor fi $1\ 0\ -1\ 0$, $0\ 1\ 0\ -1$ și $0\ 0\ 1\ -1$), iar în cazul variabilei B comparăm condițiile b1-b2 și b1-b3 (coeficienții vor fi $1\ -1\ 0$ și $1\ 0\ -1$). Ne amintim că numărul de contraste este $k - 1$, unde k reprezintă numărul de nivele ale variabilei respective. Numărul total al contrastelor de interacțiune posibile este 6 [$= 3$ (numărul de contraste în cazul variabilei A) $\times 2$ (numărul de contraste în cazul variabilei B)]. Acestea sunt : a1-a3, a2-a4 și a3-a4 în interacțiune cu contrastul b1-b2 și a1-a3, a2-a4 și a3-a4 în interacțiune cu contrastul b1-b3. Acum să specificăm două contraste de interacțiune pe care am dori să le analizăm : fie primul a1-a3 în interacțiune cu b1-b2, iar al doilea a3-a4 în interacțiune cu b1-b3. Sintaxa va fi următoarea :

```
MANOVA scoruri BY var_a(1,4) var_b(1,3)
/ERROR=WITHIN
/CONTRAST(var_a)=SPECIAL(1 1 1 1, 1 0 -1 0, 0 1 0 -1, 0 0 1 -1)
/CONTRAST(var_b)=SPECIAL(1 1 1, 1 -1 0, 1 0 -1)
/DESIGN= var_a(1) BY var_b(1), var_a(3) BY var_b(2).
```

În primul contrast de interacțiune vom verifica dacă (M1 – M4) diferă semnificativ de (M2 – M5), iar în al doilea contrast de interacțiune vom verifica dacă (M7 – M10) diferă semnificativ de (M9 – M12).

Precizăm că pot fi analizate și *contraste de interacțiune direcționale* de două tipuri : 1) *interacțiunea tendinței liniare a unei VI cu o altă VI* (atunci când prima VI este ordinală) și 2) *interacțiunea a două tendințe liniare* (dacă ambele VI sunt ordinale). Pentru primul tip, dacă interacțiunea este semnificativă atunci există tendințe liniare ale primei VI în diferite condiții ale celei de-a doua VI. În cazul celui de-al doilea tip, o interacțiune semnificativă înseamnă că tendința (tendințele) liniară a primei VI crește (sau descrește) liniar pe parcursul condițiilor celei de-a doua VI. Ne rezumăm doar la această discuție sumară în ceea ce privește cele două tipuri de contraste.

14.9. Observații finale

Există unele întrebări în ceea ce privește rezultatele la testele F în cazul ANOVA factorială la care vom căuta să răspundem în continuare.

1. *Dacă un efect principal este evidențiat ca semnificativ statistic prin intermediul testului F, este posibil ca acesta să nu fie în realitate semnificativ?* Răspunsul este da! De aceea, se recomandă verificarea tuturor efectelor principale semnificative prin intermediul testelor t pentru eșantioane independente, atunci când variabila în cauză are doar două categorii.
2. *Dacă un efect de interacțiune $A \times B$ nu este semnificativ statistic, putem totuși analiza efectele simple ale unei variabile (A sau B)?* Răspunsul este iarăși da, însă în anumite condiții :
 - a) Dacă efectul principal al variabilei A este semnificativ, iar efectul principal al variabilei B este nesemnificativ, putem analiza efectele simple ale variabilei B, însă nu vom analiza efectele simple ale variabilei A (deoarece în acest caz informațiile ar fi datorate efectului principal al variabilei A).
 - b) Reciproc, dacă efectul principal al variabilei B este semnificativ, vom putea analiza doar efectele simple ale variabilei A.
 - c) Dacă însă nici unul dintre efectele principale ale variabilelor A și B nu este semnificativ, atunci vom putea analiza oricare dintre efectele simple ale variabilelor A sau B (Iacobucci, 2001).

Într-un studiu desfășurat pe un lot de elevi de liceu am urmărit să analizăm în ce măsură nivelul inteligenței emoționale a părinților și genul elevilor determină performanța școlară a acestora din urmă. Variabilele independente sunt *nivele inteligență emoțională (IE) părinți* (două categorii : nivel scăzut *versus* ridicat) și *genul biologic al elevilor* (două categorii : masculin, feminin), iar variabila dependentă este performanța școlară.

Deschidem fișierul *factoriala_3* și aplicăm metoda ANOVA factorială. Rezultatele principale sunt prezentate în tabelul următor :

Tests of Between-Subjects Effects

Dependent Variable: performanta scolara

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	4,465 ^a	3	1,488	2,269	,093
Intercept	2667,748	1	2667,748	4066,682	,000
GEN	3,027	1	3,027	4,614	,037
N_IE_PAR	1,696E-02	1	1,696E-02	,026	,873
GEN * N_IE_PAR	2,189	1	2,189	3,338	,074
Error	29,520	45	,656		
Total	3054,900	49			
Corrected Total	33,985	48			

a. R Squared = ,131 (Adjusted R Squared = ,073)


Observăm că există un efect principal semnificativ al variabilei *gen* asupra variabilei *performanță* [$F(1, 45) = 4,614$, $p = 0,037$] și de asemenea nu există un efect principal semnificativ al variabilei *nivele IE părinți* asupra variabilei *performanță* [$F(1, 45) = 0,026$, $p = 0,873$]. De asemenea, nu există un efect de interacțiune semnificativ statistic al variabilelor *gen* și *nivele IE părinți* asupra variabilei *performanță* [$F(1, 45) = 3,349$, $p = 0,074$]. Să vedem dacă în realitate lucrurile stau așa.

Vom verifica efectul principal al variabilei *gen* asupra variabilei *performanță* prin intermediul testului *t* pentru eșantioane independente. Rezultatele obținute arată că nu există diferențe semnificative între băieți și fete în ceea ce privește performanța școlară, [$t(47) = 1,821$, $p = 0,075$]. Așadar, efectul principal al variabilei *gen* evidențiat de testul *F* în modelul ANOVA este fals.


Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means				
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference
performanta scolara	Equal variances assumed	,771	,384	-1,821	47	,075	-,4297	,2360
	Equal variances not assumed			-1,847	46,753	,071	-,4297	,2327

În acest moment știm că nu există nici un efect principal semnificativ statistic. Analizând din nou efectul de interacțiune, observăm că pragul de semnificație este destul de scăzut ($p = 0,074$), chiar dacă este mai mare decât valoarea standard 0,05, fapt ce ne determină să considerăm că în realitate ar putea exista efecte simple semnificative statistic. Să urmărim graficul de mai jos ilustrând acest efect de interacțiune.



Vom analiza efectul de interacțiune prin intermediul efectelor simple, verificând efectele simple ale variabilei *gen* în fiecare dintre condițiile variabilei *nivele IE părinți* prin procedura Split File. Vom împărți mai întâi baza de date după variabila *nivele IE părinți*.



În continuare vom aplica teste *t* pentru eșantioane independente pentru a compara mediile la variabila *performanță* în funcție de variabila *gen*.

Există un efect simplu semnificativ statistic al variabilei *gen* asupra variabilei *performanță* [$t(18) = 2,677, p = 0,015$] în condiția unui nivel scăzut al inteligenței emoționale a părinților, fetele obținând performanțe superioare băieților.

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
performanta scolara	Equal variances assumed	3,060	,097	-2,677	18	,015	-.9890	,3695	-1,765	-.2128
	Equal variances not assumed			-3,464	17,35	,003	-.9890	,2855	-1,590	-.3876

a. nivele inteligenta emotionala parinti = nivel scazut

În schimb, nu există un efect simplu semnificativ statistic al variabilei gen asupra variabilei performanță [$t(27) = 0,254$, $p = 0,802$] în condiția unui nivel ridicat al inteligenței emoționale a părinților.

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
performanta scolara	Equal variances assumed	,336	,567	-.254	27	,802	-.080	,3149	-.7260	,5662
	Equal variances not assumed			-.252	25,14	,803	-.080	,3168	-.7322	,5724

a. nivele inteligenta emotionala parinti = nivel ridicat

Capitolul 15. ANOVA simplă cu măsurători repetate

15.1. Prezentare generală

Dacă în ANOVA simplă un subiect participa doar într-o condiție experimentală, în ANOVA cu măsurători repetate un subiect participă în toate condițiile experimentale (este testat de mai multe ori). Atunci când designul conține o singură variabilă independentă, metoda presupune compararea a cel puțin trei condiții experimentale (trei variabile-pereche în SPSS).

Analiza varianțelor. În ANOVA simplă și factorială varianța datorată diferențelor interindividuale (sau intragrupuri) făcea parte din varianța eroare (neexplicată). În ANOVA cu măsurători repetate această varianță dată de diferențele interindividuale este analizată și controlată (datorită faptului că fiecare subiect participă în fiecare condiție experimentală) și astfel nu mai face parte din varianța eroare. Prin urmare varianța eroare este mai mică în designul cu măsurători repetate comparativ cu designul intergrupuri și deci tehnica ANOVA cu măsurători repetate (design intragrupuri) este mai puternică decât tehnica ANOVA simplă sau factorială (design intergrupuri), crescând șansele de a detecta diferențe între condiții, atunci când acestea există.

Condițiile de aplicare ale acestei tehnici sunt :

1. VD este cantitativă și normal distribuită (în fiecare condiție a VI) ;
2. *condiția de sfericitate*, testată prin testul W al lui Mauchly, presupune omogenitatea varianțelor atât în cadrul condițiilor experimentale cât și în cadrul diferențelor dintre două condiții (de exemplu, pentru trei condiții experimentale a_1 , a_2 și a_3 , dacă am crea trei noi variabile reprezentând diferențele dintre fiecare două condiții, respectiv $b_1 = a_1 - a_2$, $b_2 = a_1 - a_3$ și $b_3 = a_2 - a_3$, atunci varianțele variabilelor b_1 , b_2 și b_3 ar trebui să fie de asemenea egale). Sfericitatea poate fi văzută și ca o omogenitate a covarianțelor, respectiv a coeficienților de corelație dintre fiecare două condiții experimentale ; nerespectarea acesteia crește șansele de a comite eroarea de tipul I (Sava, 2004) ;
3. fiecare subiect este testat în fiecare condiție experimentală.

Condiția de sfericitate este destul de rar îndeplinită în studiile din științele sociale, încălcarea acesteia influențând în mod serios rezultatele. Dacă rezultatele la testul W Mauchly sunt *nesemnificative* statistic ($p > 0,05$) condiția de sfericitate este îndeplinită. În cazul încălcării condiției de sfericitate avem două alternative : fie ajustăm gradele de libertate în citirea valorilor lui F din ANOVA (folosind corecțiile Greenhouse-Geisser sau Huynh-Feldt), fie folosim analiza de varianță multivariată (MANOVA).

Și în cazul acestei tehnici vom apela la teste de contrast sau teste post hoc, deoarece testul F general testează doar dacă există diferențe între diferitele condiții experimentale. Testele de contrast disponibile sunt doar cele standardizate, iar în ceea ce privește testele post hoc acestea sunt doar trei: LSD, Bonferroni și Sidak – testul Bonferroni fiind cel recomandat.

15.2. Aplicarea metodei ANOVA simplă cu măsurători repetate

Presupunem că intenționăm să derulăm un program de training în vederea dezvoltării abilităților de autoprezentare, însă nu știm dacă durata acestuia ar trebui să fie de 9 ore sau ar trebui să ne oprim după 6 ore: vom verifica aceasta într-un studiu-pilot. Având un chestionar de autoprezentare cu trei forme paralele, vom aplica o primă formă înaintea începerii trainingului (condiția de pretest sau *fără training, 0 ore*), apoi a doua formă după 6 ore de training (condiția posttest 1) și a treia formă după 9 ore (condiția posttest 2). Designul cercetării este prezentat mai jos.


Tabelul 15.1. Design ANOVA simplă cu măsurători repetate

Subiecți	Autoprezentare		
	pretest (0 ore training)	posttest 1 (training 6 ore)	posttest 2 (training 9 ore)
1	21	35	33
2	24	38	38
3	24	42	43
...	...	...	...
19	40	55	54


Variabila dependentă va fi *autoprezentare*, iar variabila independentă *momentul testării* cu trei nivele: pretest, posttest 1 și posttest 2. Vom verifica dacă:

1. abilitățile de autoprezentare sunt mai dezvoltate în condiția de posttest 1 față de condiția pretest (primul pas în validarea trainingului);
2. creșterea duratei trainingului de la 6 la 9 ore nu conduce la o dezvoltare semnificativă a abilităților de autoprezentare (eficientizarea costurilor).


Deschidem fișierul *ANOVA_m_repetate_1*. Calea în SPSS este: *Analyze* → *General Linear Model* → *Repeated Measures*.



În câmpul *Within-Subject Factor Name* ștergem factor 1 și scriem *autoprez*, apoi în câmpul *Number of Levels* modificăm 3 (numărul de condiții ale VI), clic pe butonul *Add* și clic pe butonul *Define*.



În fereastra deschisă trecem din câmpul din dreapta cele trei variabile reprezentând condițiile experimentale (în ordine) în câmpul *Within-Subjects Variables*.



Pentru a aplica teste post hoc, facem clic pe butonul *Options* și din câmpul din stânga-sus trecem variabila creată *autoprez* în câmpul din dreapta (*Display Means for*); activăm apoi opțiunea *Compare main effects* prezentă imediat mai jos, alegem metoda Bonferroni ca metodă de ajustare a intervalului de încredere (în câmpul *Confidence interval adjustment*), opțiunea *Descriptive statistics* și clic *Continue*.

Repeated Measures: Options

Estimated Marginal Means:

Factor(s) and Factor Interactions:

(OVERALL)
autoprez

Display Means for:

autoprez

☒ Compare main effects

Confidence interval adjustment:

Bonferroni

Display:

☒ Descriptive statistics
☐ Estimates of effect size
☐ Observed power
☐ Parameter estimates
☐ SSCP matrices
☐ Residual SSCP matrix

☐ Transformation matrix
☐ Homogeneity tests
☐ Contrast as level plots
☐ Residual plots
☐ Lack of fit test
☐ General estimable function

Significance level: .05 Confidence intervals are 95%

Continue Cancel Help

Activăm apoi butonul *Contrast* și alegem contrastele repetate (*Repeated*), clic *Change* și *Continue*.

Repeated Measures: Contrasts

Factors:

autoprez(Repeated)


Continue
Cancel
Help

Change Contrast

Contrast: Repeated Change

Reference Category: ☒ Last ☐ First

Pentru afișarea graficului apăsăm butonul *Plots*, trecem variabila *autoprezentare* în câmpul *Horizontal Axis*, clic pe butonul *Add*, clic *Continue* și clic *OK*.



15.3. Interpretarea outputului

Tabelul *Descriptive Statistics* prezintă mediile și abaterile standard la variabila *autoprezentare* pentru fiecare dintre cele trei nivele ale variabilei independente : pretest, training 6 ore și training 9 ore.

Descriptive Statistics

	Mean	Std. Deviation	N
pretest	30,68	4,92	19
training sase ore	44,21	5,35	19
training noua ore	44,47	6,10	19

În tabelul *Mauchly's Test of Sphericity* este verificată condiția de sfericitate. Cum rezultatul testului Mauchly $W = 0,726$ este nesemnificativ statistic ($p > 0,05$), condiția de sfericitate este îndeplinită. În partea din dreapta a tabelului sunt prezentate diferite valori ale coeficientului epsilon. O valoare epsilon egală cu 1 reprezintă îndeplinirea

sfericității. Valoarea minimă a lui epsilon este $\frac{1}{k-1}$, unde k reprezintă numărul de grupe

experimentale (în cazul de față, valoarea minimă este 0,500). Dacă sfericitatea nu era îndeplinită (valoarea testului Mauchly W ar fi fost semnificativă), atunci ne-am fi orientat spre coeficienții epsilon Greenhouse-Geisser (0,785) și Huynh-Feldt (0,874) pentru a hotărî cum vom ajusta gradele de libertate în citirea testului F general. Dacă coeficienții epsilon sunt $< 0,75$, atunci alegem corecția Greenhouse-Geisser, iar dacă aceștia sunt $> 0,75$ folosim corecția Huynh-Feldt (Leech, Barrett și Morgan, 2005). Deoarece condiția de sfericitate este îndeplinită nu vom apela la niciuna dintre cele două corecții.

Mauchly's Test of Sphericity^a

Measure: MEASURE_1

Within Subjects Effect	Mauchly's W	Approx. Chi-Square	df	Sig.	Epsilon ^a		
					Greenhouse-Geisser	Huynh-Feldt	Lower-bound
AUTOPREZ	,726	5,437	2	,066	,785	,847	,500

Tests the null hypothesis that the error covariance matrix of the orthonormalized transformed dependent variables is proportional to an identity matrix.

- a. May be used to adjust the degrees of freedom for the averaged tests of significance. Corrected tests are displayed in the Tests of Within-Subjects Effects table.

b.

Design: Intercept

Within Subjects Design: AUTOPREZ

Tabelul *Tests of Within-Subjects Effects* este tabelul principal din output, conținând rezultatele la testele F generale. *Condiția de sfericitate este îndeplinită, așadar vom urmări valoarea testului F de pe primul rând: [F (2, 36) = 417,658, p = 0,000].* Dacă sfericitatea nu ar fi fost îndeplinită ar fi trebuit să alegem între testele F corespunzătoare uneia dintre cele două corecții în funcție de criteriul menționat mai sus. În cazul ajustării Greenhouse-Geisser F general ar fi fost [F (1,570, 28,264) = 417,658, p = 0,000], unde gradele de libertate (2, 36) au fost înmulțite cu epsilon (0,785); pentru ajustarea Huynh-Feldt, [F (1,694, 30,494) = 417,658, p = 0,000]. În situația de față, valorile testului F sunt identice. Deoarece rezultatele la testul F general sunt semnificative, rezultă că există diferențe semnificative între cele trei condiții în ceea ce privește abilitățile de autoprezentare.

Tests of Within-Subjects Effects

Measure: MEASURE_1

Source		Type III Sum of Squares	df	Mean Square	F	Sig.
AUTOPREZ	Sphericity Assumed	2363,474	2	1181,737	417,658	,000
	Greenhouse-Geisser	2363,474	1,570	1505,194	417,658	,000
	Huynh-Feldt	2363,474	1,694	1395,104	417,658	,000
	Lower-bound	2363,474	1,000	2363,474	417,658	,000
Error(AUTOPREZ)	Sphericity Assumed	101,860	36	2,829		
	Greenhouse-Geisser	101,860	28,264	3,604		
	Huynh-Feldt	101,860	30,494	3,340		
	Lower-bound	101,860	18,000	5,659		

Pentru a afla între care dintre cele trei condiții sunt semnificative diferențele vom aplica fie teste de contrast, fie teste post hoc. Rezultatele la testele de contrast sunt prezentate în tabelul *Tests of Within-Subjects Contrasts*; observăm că există diferențe semnificative între pretestare și training1 [F (1, 18) = 660,49, p = 0,000] și nu există

diferențe semnificative între training1 și training2 [$F(1, 18) = 0,397, p = 0,537$]. Așadar ipotezele sunt confirmate.

Tests of Within-Subjects Contrasts

Measure: MEASURE_1

Source	AUTOPREZ	Type III Sum of Squares	df	Mean Square	F	Sig.
AUTOPREZ	Level 1 vs. Level 2	3476,263	1	3476,263	660,490	,000
	Level 2 vs. Level 3	1,316	1	1,316	,397	,537
Error(AUTOPREZ)	Level 1 vs. Level 2	94,737	18	5,263		
	Level 2 vs. Level 3	59,684	18	3,316		

Rezultatele la testele post hoc Bonferroni sunt prezente în tabelul *Pairwise Comparisons* și confirmă rezultatele de mai sus. Observăm că există diferențe semnificative între condiția pretest și posttest 1 [Bonferroni $t = \frac{13,526}{0,526} = 25,71, p = 0,000$], între condiția pretest și condiția posttest 2 [Bonferroni $t = \frac{13,789}{0,665} = 20,74, p = 0,000$] și nu există diferențe semnificative între condiția posttest 1 și posttest 2 [Bonferroni $t = \frac{0,263}{0,418} = 0,63, p = 1,000$]. Valoarea efectivă a testului Bonferroni t a fost calculată la fel ca în ANOVA factorială, împărțind diferența de medii la eroarea standard.

Pairwise Comparisons

Measure: MEASURE_1

(I) AUTOPREZ	(J) AUTOPREZ	Mean Difference (I-J)	Std. Error	Sig. ^a	95% Confidence Interval for Difference ^a	
					Lower Bound	Upper Bound
1	2	-13,526*	,526	,000	-14,915	-12,137
	3	-13,789*	,665	,000	-15,544	-12,035
2	1	13,526*	,526	,000	12,137	14,915
	3	-,263	,418	1,000	-1,366	,839
3	1	13,789*	,665	,000	12,035	15,544
	2	,263	,418	1,000	-,839	1,366

Based on estimated marginal means


*. The mean difference is significant at the ,05 level.

a. Adjustment for multiple comparisons: Bonferroni.


Ilustrarea grafică a rezultatelor este prezentată mai jos.

Estimated Marginal Means of MEASURE_1


Dezvoltarea abilitatilor de autoprezentare




Dacă dorim, putem înlocui graficul prin linii afișat de ANOVA cu cel prin bare din meniul *Graphs-Bar*. Selectăm opțiunea *Simple*, iar din câmpul *Data in Chart Area* opțiunea *Summaries of separate variables* și clic *Define*.



Trecem variabilele *pretest*, *posttest 1* și *posttest 2* în câmpul din dreapta *Bars Represent* și clic *OK*.



Noul grafic va arăta astfel :



15.4. Mărimea efectului

Calcularea mărimii efectului se face aplicând formula :

$$r = \sqrt{\frac{F(1, df_R)}{F(1, df_R) + df_R}}$$

unde $F(1, df_R)$ este rezultatul la testul de contrast F.

În cazul contrastului 1 (pretest *versus* training 1),

$$r = \sqrt{\frac{660,490}{660,490 + 18}} = \sqrt{\frac{660,490}{678,490}} = 0,99$$

Aplicând testele post hoc Bonferroni, ținând cont că $F = t^2$, gradele de libertate pentru testul F sunt $(1, df_{\text{eroare}})$, iar df_{eroare} pentru teste t eşantioane perechi este egal cu numărul de subiecți - 1,

$$df_{\text{eroare}} = (nr\_subiecti - 1)$$

fomula de calcul a mărimii efectelor va fi :

$$r = \frac{t}{\sqrt{t^2 + df_{\text{eroare}}}}$$

Știind de la testele post hoc că există diferențe semnificative între condiția pretest și

posttest 1, Bonferroni $t(18) = 25,71$, mărimea efectului va fi $r = \frac{25,71}{\sqrt{661+18}} = 0,99$.

Totodată, există diferențe semnificative între condiția pretest și posttest 2, Bonferroni $t(18) = 20,74$, mărimea efectului va fi $r = 0,99$.

15.5. Prezentarea rezultatelor

Pentru a verifica efectul duratei de desfășurare a unui training (0 ore, 6 ore, 9 ore) asupra dezvoltării abilităților de autoprezentare, am aplicat metoda ANOVA simplă cu măsurători repetate. Rezultatele indică faptul că aplicarea trainingului a avut efect asupra dezvoltării abilităților de autoprezentare, $F(2, 36) = 417,658$, $p < 0,001$. S-a constatat o dezvoltare semnificativă a abilităților de autoprezentare în urma trainingului de 6 ore, $F(1, 18) = 660,49$, $p < 0,001$, $r = 0,87$, mărimea efectului $r = 0,99$, nu însă și o dezvoltare semnificativă a acestor abilități atunci când mărim durata trainingului de la 6 ore la 9 ore $F(1, 18) = 0,397$, $p = 0,537$. Se constată astfel un efect foarte puternic al trainingului de 6 ore asupra dezvoltării abilităților de autoprezentare. Mediile și deviațiile standard la variabila *autoprezentare* pentru fiecare dintre treptele VI sunt prezentate în tabelul 15.2.

Tabelul 15.2. Mediile și deviațiile standard la variabila autoprezentare pentru fiecare dintre treptele VI (momentele testării)

Treptele VI	M	SD
Pretestare	30,68	4,92
Training 6 ore	44,21	5,35
Training 9 ore	44,47	6,10

Capitolul 16. ANOVA factorială cu măsurători repetate

Condițiile de aplicare sunt aceleași ca în ANOVA simplă cu măsurători repetate.

Metoda ANOVA factorială cu măsurători repetate urmărește analizarea efectelor a două sau mai multe VI asupra unei VD, în condiția confruntării (expunerii) aceluiasi lot de subiecți cu toate nivelele variabilelor independente.


16.1. Aplicarea ANOVA factorială cu măsurători repetate

Să presupunem că desfășurăm un experiment în care studiem efectul nivelului de dificultate a sarcinii și a nivelului expectanțelor de autoeficiență în sarcină asupra performanței în sarcină. Cele două VI sunt : *nivelul de dificultate a sarcinii (sarcină)* cu trei categorii (dificultate scăzută, medie și ridicată) și *nivelul expectanțelor de autoeficiență în sarcină (expectanțe)* cu două categorii (expectanțe scăzute și ridicate). VD este *performanța în sarcină (performanță)*. Design-ul experimental este de tipul 3x2. Fiecare subiect participă în fiecare dintre cele șase condiții experimentale.


Tabelul 16.1. Design 2x3 ANOVA factorială cu măsurători repetate

Subiecți	Sarcină ușoară		Sarcină medie		Sarcină dificilă	
	Expectanțe scăzute	Expectanțe ridicate	Expectanțe scăzute	Expectanțe ridicate	Expectanțe scăzute	Expectanțe ridicate
	s1e1	s1e2	s2e1	s2e2	s3e1	s3e2
1	8,30	9,36	7,53	9,52	8,20	8,73
2	8,91	9,52	9,46	9,64	8,76	7,86
...	...	...	...	...	...	...
30	8,80	9,70	8,20	8,66	8,00	8,80

Deschidem fișierul *ANOVA_m_repetate_2*. Calea în SPSS este : *Analyze* → *General Linear Model* → *Repeated Measures*. În câmpul *Within-Subject Factor Name* ștergem Factor1 și trecem prima VI – *sarcina* –, apoi trecem în câmpul *Number of Levels* cifra „3” (numărul de categorii ale acestei VI), apoi clic pe butonul *Add*. Revenim în câmpul *Within-Subject Factor Name* unde trecem a doua VI – *expect* –, apoi în câmpul *Number of Levels* trecem cifra „2” (numărul de categorii ale celei de-a doua VI), apoi clic pe butonul *Add* și clic *Define*.



Trecem fiecare variabilă (în ordine) în câmpul *Within-Subjects Variables* (observăm că în acest câmp cifrele din paranteză corespund condițiilor experimentale (11, 12, 21 etc).



Activăm butonul *Options*, în caseta de dialog bifăm opțiunea *Descriptive Statistics*, trecem fiecare VI în câmpul *Display Means for*, activăm opțiunea *Compare main effect* și alegem testul post hoc *Bonferroni* pentru analiza efectelor principale și clic *Continue*.

Repeated Measures: Options

Estimated Marginal Means

Factor(s) and Factor Interactions:

(OVERALL)
sarcina
expect
sarcina*expect

Display Means for:

(OVERALL)
sarcina
expect
sarcina*expect

☒ Compare main effects

Confidence interval adjustment:
Bonferroni

Display

☒ Descriptive statistics
☐ Estimates of effect size
☐ Observed power
☐ Parameter estimates
☐ SSCP matrices
☐ Residual SSCP matrix

☐ Transformation matrix
☐ Homogeneity tests
☐ Spread vs. level plots
☐ Residual plots
☐ Lack of fit test
☐ General estimable function

Significance level: .05 Confidence intervals are 95%

Continue Cancel Help

Activăm în continuare butonul *Contrasts*. Alegem utilizarea contrastelor simple pentru a compara fiecare grupă cu ultima. Selectăm prima variabilă *sarcina*, alegem din câmpul *Change Contrast* contrastul *Simple*, clic pe butonul *Change* pentru a fi activat contrastul ales, apoi selectăm variabila *expect* și alegem din nou contrastul *Simple*; clic pe butonul *Change* și clic *Continue*.

Repeated Measures: Contrasts

Factors:

sarcina(Simple)
expect(Simple)

Continue
Cancel
Help


Change Contrast

Contrast: Simple Change

Reference Category: ☒ Last ☐ First

Pentru reprezentarea grafică a efectelor principale și de interacțiune vom activa butonul *Plots*. Trecem prima variabilă independentă *sarcină* în câmpul *Horizontal Axis* și clic pe butonul *Add* (vom ilustra astfel grafic efectul principal al variabilei *sarcină*), apoi trecem variabila independentă *expect* în câmpul *Horizontal Axis* și clic pe butonul *Add*

(vom ilustra grafic efectul principal al variabilei *expect*) ; în final vom trece variabila *sarcina* în câmpul *Horizontal Axis* și variabila *expect* în câmpul *Separate Lines*, clic *Add*, clic *Continue* și *OK*.



16.2. Interpretarea outputului în ANOVA factorială cu măsurători repetate

În primul tabel, *Within-Subjects Factor*, sunt prezentate în partea stângă VI *sarcina* și *expect*, fiecare cu nivelele corespunzătoare, iar în partea dreaptă VD (variabilele așa cum apar în baza de date). Este un tabel cu ajutorul căruia putem verifica dacă am introdus corect variabilele în câmpul *Within-Subjects Variables*.

Within-Subjects Factors

Measure: MEASURE_1

SARCINA	EXPECT	Dependent Variable
1	1	S1E1
	2	S1E2
2	1	S2E1
	2	S2E2
3	1	S3E1
	2	S3E2

Din tabelul *Descriptive Statistics* putem urmări mediile și deviațiile standard în cazul fiecărei condiții experimentale.

Descriptive Statistics

	Mean	Std. Deviation	N
sarcina usoara + expectante scazute	8,6317	,6235	30
sarcina usoara + expectante ridicate	8,7173	,8257	30
sarcina medie + expectante scazute	8,5040	,8753	30
sarcina medie+ expectante ridicate	8,8787	,7293	30
sarcina dificila + expectante scazute	7,8100	,7806	30
sarcina dificila + expectante ridicate	8,6430	,8198	30

În tabelul *Mauchly's Test of Sphericity* este verificată condiția de sfericitate pentru fiecare VI cu cel puțin trei categorii sau orice interacțiune cu o astfel de VI. Observăm că testul W al lui Mauchly este nesemnificativ atât pentru variabila *sarcina* ($p = 0,874$), cât și pentru interacțiunea *sarcina * expect* ($p = 0,999$), deci condiția de sfericitate este îndeplinită.

Mauchly's Test of Sphericity^a

Measure: MEASURE_1

Within Subjects Effect	Mauchly's W	Approx. Chi-Square	df	Sig.	Epsilon ^a		
					Greenhouse-Geisser	Huynh-Feldt	Lower-bound
SARCINA	,990	,269	2	,874	,991	1,000	,500
EXPECT	1,000	,000	0	,	1,000	1,000	1,000
SARCINA * EXPECT	1,000	,001	2	,999	1,000	1,000	,500

Tests the null hypothesis that the error covariance matrix of the orthonormalized transformed dependent variables is proportional to an identity matrix.

- a. May be used to adjust the degrees of freedom for the averaged tests of significance. Corrected tests are displayed in the Tests of Within-Subjects Effects table.
- b. Design: Intercept
Within Subjects Design: SARCINA+EXPECT+SARCINA*EXPECT

Din tabelul *Test of Within-Subjects Effects* (tabelul principal ANOVA) constatăm că există un prim efect principal semnificativ al variabilei *sarcina* asupra performanței [$F(2,58) = 7,784$, $p = 0,001$], există un al doilea efect principal semnificativ al variabilei *expect* asupra performanței [$F(1, 29) = 10,469$, $p = 0,003$] și există un efect de interacțiune semnificativ al variabilelor *sarcina* și *expect* asupra performanței [$F(2,58) = 3,648$, $p = 0,032$].

Tests of Within-Subjects Effects

Measure: MEASURE_1

Source		Type III Sum of Squares	df	Mean Square	F	Sig.
SARCINA	Sphericity Assumed	8,341	2	4,171	7,784	,001
	Greenhouse-Geisser	8,341	1,981	4,211	7,784	,001
	Huynh-Feldt	8,341	2,000	4,171	7,784	,001
	Lower-bound	8,341	1,000	8,341	7,784	,009
Error(SARCINA)	Sphericity Assumed	31,076	58	,536		
	Greenhouse-Geisser	31,076	57,450	,541		
	Huynh-Feldt	31,076	58,000	,536		
	Lower-bound	31,076	29,000	1,072		
EXPECT	Sphericity Assumed	8,364	1	8,364	10,469	,003
	Greenhouse-Geisser	8,364	1,000	8,364	10,469	,003
	Huynh-Feldt	8,364	1,000	8,364	10,469	,003
	Lower-bound	8,364	1,000	8,364	10,469	,003
Error(EXPECT)	Sphericity Assumed	23,167	29	,799		
	Greenhouse-Geisser	23,167	29,000	,799		
	Huynh-Feldt	23,167	29,000	,799		
	Lower-bound	23,167	29,000	,799		
SARCINA * EXPECT	Sphericity Assumed	4,260	2	2,130	3,648	,032
	Greenhouse-Geisser	4,260	2,000	2,130	3,648	,032
	Huynh-Feldt	4,260	2,000	2,130	3,648	,032
	Lower-bound	4,260	1,000	4,260	3,648	,066
Error(SARCINA* EXPECT)	Sphericity Assumed	33,872	58	,584		
	Greenhouse-Geisser	33,872	57,998	,584		
	Huynh-Feldt	33,872	58,000	,584		
	Lower-bound	33,872	29,000	1,168		

16.3. Analiza efectelor principale

Analiza efectelor principale se poate face fie prin teste de contrast standardizate, fie prin teste post hoc (*Atenție!* Testele post hoc se găsesc în meniul Options; testele post hoc din meniul *Post Hoc* sunt disponibile numai pentru VI intergrupuri, în cazul designurilor mixte). Aplicarea unor teste de contrast nestandardizate pentru verificarea efectelor simple se poate face prin intermediul sintaxelor, însă nu vom insista acum asupra acestora. Să analizăm rezultatele la testele post hoc.

Efectul principal al variabilei *sarcina*

În tabelul *Pairwise Comparisons* corespunzător variabilei *sarcina* constatăm că există diferențe semnificative între condițiile 1 și 3 (dificultate scăzută *versus* dificultate ridicată) [Bonferroni $t = 3,50$, $p = 0,004$], între condițiile 2 și 3 (dificultate medie *versus*

dificultate ridicată) [Bonferroni $t = 3,345$, $p = 0,007$] și nu există diferențe semnificative între condițiile 1 și 2 (dificultate scăzută *versus* dificultate medie), [Bonferroni $t = 0,125$, $p = 1,00$].

Pairwise Comparisons

Measure: MEASURE_1


(I) SARCINA	(J) SARCINA	Mean Difference (I-J)	Std. Error	Sig. ^a	95% Confidence Interval for Difference ^a	
					Lower Bound	Upper Bound
1	2	-1,683E-02	,134	1,000	-,358	,324
	3	,448*	,128	,004	,124	,772
2	1	1,683E-02	,134	1,000	-,324	,358
	3	,465*	,139	,007	,112	,818
3	1	-,448*	,128	,004	-,772	-,124
	2	-,465*	,139	,007	-,818	-,112

Based on estimated marginal means

*. The mean difference is significant at the ,05 level.

a. Adjustment for multiple comparisons: Bonferroni.

O ilustrare grafică a efectului principal este prezentată mai jos.



Efectul principal al variabilei *expectanțe*

În ceea ce privește rezultatele la testul post hoc în cazul variabilei *expectanțe* prezentate în tabelul *Pairwise Comparisons* corespunzător acestei variabile, acestea sunt redundante cu rezultatele la testul F general corespunzător efectului principal al variabilei independente (deoarece variabila *expect* are doar două nivele); există diferențe semnificative între cele două condiții ale variabilei *expectanțe* (ridicate *versus* scăzute), [Bonferroni $t = 3,24$, $p = 0,003$].

Pairwise Comparisons

Measure: MEASURE_1


(I) EXPECT	(J) EXPECT	Mean Difference (I-J)	Std. Error	Sig. ^a	95% Confidence Interval for Difference ^a	
					Lower Bound	Upper Bound
1	2	-.431*	,133	,003	-.704	-.159
2	1	,431*	,133	,003	,159	,704

Based on estimated marginal means

*. The mean difference is significant at the ,05 level.

a. Adjustment for multiple comparisons: Bonferroni.

O ilustrare grafică a efectului principal este prezentată mai jos.



Să urmărim acum rezultatele la testul de contrast prezentate în tabelul *Tests of Within-Subjects Contrasts*, care le confirmă pe cele obținute prin testele post hoc. În cazul variabilei *sarcină*, există diferențe semnificative între condițiile 1 și 3 [$F(1, 29) = 12,331, p = 0,001$] și între condițiile 2 și 3 [$F(1, 29) = 11,200, p = 0,002$]. În cazul variabilei *expectanțe*, există diferențe semnificative între condițiile 1 și 2 [$F(1, 29) = 10,469, p = 0,003$]. De asemenea, în cazul interacțiunii dintre variabilele *sarcină* și *expect*, există diferențe semnificative între diferența dintre performanțele în condiție de expectanțe scăzute și ridicate în condiția de sarcină ușoară ($M1 - M2$) și diferența dintre performanțele în condiție de expectanțe scăzute și ridicate în condiția de sarcină dificilă ($M5 - M6$), altfel spus $M1 - M3 \neq M5 - M6$ [$F(1, 29) = 7,209, p = 0,012$] (în ultimul caz este vorba despre *contraste de interacțiune* specifice analizei efectelor de interacțiune despre care vom discuta în continuare).

Tests of Within-Subjects Contrasts

Measure: MEASURE_1

Source	SARCINA	EXPECT	Type III Sum of Squares	df	Mean Square	F	Sig.
SARCINA	Level 1 vs. Level 3		6,021	1	6,021	12,331	,001
	Level 2 vs. Level 3		6,482	1	6,482	11,200	,002
Error(SARCINA)	Level 1 vs. Level 3		14,161	29	,488		
	Level 2 vs. Level 3		16,784	29	,579		
EXPECT		Level 1 vs. Level 2	5,576	1	5,576	10,469	,003
Error(EXPECT)		Level 1 vs. Level 2	15,445	29	,533		
SARCINA * EXPECT	Level 1 vs. Level 3	Level 1 vs. Level 2	16,755	1	16,755	7,209	,012
	Level 2 vs. Level 3	Level 1 vs. Level 2	6,302	1	6,302	2,700	,111
Error(SARCINA* EXPECT)	Level 1 vs. Level 3	Level 1 vs. Level 2	67,405	29	2,324		
	Level 2 vs. Level 3	Level 1 vs. Level 2	67,682	29	2,334		


16.4. Analiza efectelor de interacțiune

Analiza efectelor de interacțiune se face atât prin analiza efectelor simple, cât și prin analiza contrastelor de interacțiune.

Tabelul 16.2. Designul cercetării 2 × 3 ANOVA factorială cu măsurători repetate

		Dificultatea sarcinii		
		ușoară	medie	ridică
Expectanțe	scăzute	s1e1 (M1)	s2e1 (M3)	s3e1 (M5)
	ridicate	s1e2 (M2)	s2e2 (M4)	s3e2 (M6)

O ilustrare grafică a efectului de interacțiune este prezentată mai jos.



16.4.1. Analiza efectelor simple

Analiza efectelor simple poate fi realizată pe două căi: fie prin aplicarea testelor t pentru eşantioane perechi, fie prin intermediul sintaxelor. Vom alege să studiem efectele simple ale VI sarcina în cadrul fiecărei condiții a VI expect sau efectele simple ale VI expect în cadrul fiecărei condiții a VI sarcina. Altfel spus, vom compara grupurile (mediile) pe verticală sau pe orizontală în design. Să analizăm efectele simple ale VI sarcina.

16.4.1.1. Analiza efectelor simple prin intermediul testelor t

a) Efectele simple ale variabilei sarcina

Analiza efectelor simple ale VI sarcina prin intermediul testelor t pentru eşantioane perechi se face mai întâi în condiție de expectanțe scăzute prin compararea mediilor M1 și M3, M3 și M5 și M1 și M5, iar apoi în condiție de expectanțe ridicate prin compararea mediilor M2 și M4, M2 și M6 și M2 și M6.

Deoarece vom aplica șase teste t va trebui să ajustăm pragul de semnificație prin metoda Bonferroni, raportând rezultatele obținute la pragul $p = \frac{0,05}{6} = 0,008$.

Efectul simplu al variabilei sarcina în condiție de expectanțe scăzute

Vom aplica teste t pentru eşantioane perechi pentru a compara variabilele s1e1 și s2e1, apoi s1e1 și s3e1 și s2e1 și s3e1 („e” va fi însoțit mereu de „1”, deoarece suntem în condiția de expectanțe scăzute). Am fi putut de asemenea aplica metoda ANOVA simplă cu măsurători repetate.

Rezultatele obținute sunt prezentate în tabelul *Paired Samples Test* de mai jos. Observăm că există diferențe semnificative doar între condițiile s1e1 și s3e1 [$t(29) = 4,406$, $p = 0,000$] și între condițiile s2e1 și s3e1 [$t(29) = 3,538$, $p = 0,001$], nu și între condițiile s1e1 și s2e1 [$t(29) = 0,656$, $p = 0,517$].

Paired Samples Test

		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	sarcina usoara + expectante scazute - sarcina medie + expectante scazute	,1277	1,0653	,1945	-,2701	,5254	,656	29	,517
Pair 2	sarcina usoara + expectante scazute - sarcina dificila + expectante scazute	,8217	1,0214	,1865	,4403	1,2031	4,406	29	,000
Pair 3	sarcina medie + expectante scazute - sarcina dificila + expectante scazute	,6940	1,0742	,1961	,2929	1,0951	3,538	29	,001

Efectul simplu al variabilei sarcina în condiție de expectanțe ridicate

Vom aplica teste t pentru eșantioane perechi pentru a compara variabilele s1e2 și s2e2, apoi s1e2 și s3e2 și s2e2 și s3e2 („e” va avea mereu „2”, deoarece suntem în condiția de expectanțe ridicate).

Rezultatele obținute sunt prezentate în tabelul *Paired Samples Test* de mai jos. Observăm că nu există diferențe semnificative între condițiile s1e2 și s2e2 [$t(29) = 0,835$, $p = 0,411$], nu există diferențe semnificative între condițiile s1e2 și s3e2 [$t(29) = 0,389$, $p = 0,700$] și nici între condițiile s2e2 și s3e2 [$t(29) = 1,193$, $p = 0,242$].

Paired Samples Test

		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	sarcina usoara + expectante ridicate - sarcina medie+ expectante ridicate	-,1613	1,0587	,1933	-,5566	,2340	-,835	29	,411
Pair 2	sarcina usoara + expectante ridicate - sarcina dificila + expectante ridicate	7,4E-02	1,0466	,1911	-,3165	,4652	,389	29	,700
Pair 3	sarcina medie+ expectante ridicate - sarcina dificila + expectante ridicate	,2357	1,0819	,1975	-,1683	,6396	1,193	29	,242

b) Efectele simple ale variabilei expectanțe

Analiza efectelor simple ale VI expectanțe prin intermediul testelor t pentru eșantioane pereche se face mai întâi în condiție de sarcină ușoară prin compararea mediilor M1 și M2, apoi în condiție de sarcină de dificultate medie prin compararea mediilor M3 și M4, iar în final în condiție de sarcină de dificultate ridicată prin compararea mediilor M5 și M6.

Deoarece vom aplica trei teste t va trebui să ajustăm pragul de semnificație prin metoda Bonferroni, raportând rezultatele obținute la pragul $p = \frac{0,05}{3} = 0,016$.

Efectul simplu al variabilei expectanțe în condiție de sarcină de dificultate ușoară

Vom aplica testul t pentru eșantioane perechi pentru a compara variabilele s1e1 și s1e2. Conform rezultatelor obținute și prezentate în tabelul *Paired Samples Test*, nu există diferențe semnificative între condițiile s1e1 și s1e2 [$t(29) = 0,415$, $p = 0,681$].

Paired Samples Test

		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	sarcina usoara + expectante scazute - sarcina usoara + expectante ridicate	-9,E-02	1,1294	,2062	-,5074	,3361	-,415	29	,681

Efectul simplu al variabilei expectanțe în condiție de sarcină de dificultate medie

Conform rezultatelor obținute la testul t pentru eșantioane perechi pentru a compara variabilele $s2e1$ și $s2e2$ și prezentate în tabelul *Paired Samples Test*, nu există diferențe semnificative între condițiile $s2e1$ și $s2e2$ [$t(29) = 1,867$, $p = 0,072$].

Paired Samples Test									
		Paired Differences				t	df	Sig. (2-tailed)	
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower				Upper
Pair 1	sarcina medie + expectante scazute - sarcina medie + expectante ridicate	-.375	1,0994	,2007	-.7852	,0359	-1,867	29	,072

Efectul simplu al variabilei expectanțe în condiție de sarcină de dificultate ridicată

Conform rezultatelor obținute la testul t pentru eșantioane perechi pentru a compara variabilele $s3e1$ și $s3e2$ și prezentate în tabelul *Paired Samples Test*, există diferențe semnificative între condițiile $s3e1$ și $s3e2$ [$t(29) = 3,790$, $p = 0,001$].


Paired Samples Test									
		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	sarcina dificila + expectante sazute - sarcina dificila + expectante ridicate	-.8330	1.2039	.2198	-1.28	-.3835	-3.790	29	.001

16.4.1.2. Analiza efectelor simple prin Intermediul sintaxelor

a) Analiza efectelor simple ale variabilei sarcina

Analiza efectelor simple ale VI sarcina prin intermediul sintaxelor se va face într-un prim pas global, în cadrul fiecărei condiții a variabilei *expect* (asemenea unei ANOVA simple cu măsurători repetate), urmând să verificăm la pasul 2 comparațiile-pereche care ne interesează (dacă rezultatele la primul pas sunt semnificative statistic). Pentru analiza de la primul pas sintaxa va fi următoarea :

```
MANOVA s1e1 s1e2 s2e1 s2e2 s3e1 s3e2
/WSFACTORS=sarcina(3) expect(2)
/PRINT=SIGNIF(AVONLY)
/WSDESIGN=sarcina WITHIN expect(1), sarcina WITHIN expect(2).
```



```

MANOVA s1e1 s1e2 s2e1 s2e2 s3e1 s3e2
/WSFACTORS=sarcina(3) expect(2)
/PRINT=SIGNIF(AVONLY)
/WSDESIGN=sarcina WITHIN expect(1), sarcina WITHIN expect(2).
  
```

Efectele simple sunt specificate în cadrul subcomandei **WSDESIGN**. Vom specifica efectul simplu al unei VI pentru fiecare nivel al celeilalte VI. Să analizăm efectul simplu al VI *sarcina* în condiție de expectanțe scăzute [expect(1)], apoi efectul simplu al VI *sarcina* în condiție de expectanțe ridicate [expect(2)]. Rezultatele relevante sunt prezentate mai jos.


Tests involving 'SARCINA WITHIN EXPECT(1)' Within-Subject Effect.					
AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	32.21	58	.56		
SARCINA WITHIN EXPECT(1)	11.73	2	5.87	10.56	.000

Tests involving 'SARCINA WITHIN EXPECT(2)' Within-Subject Effect.					
AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	32.74	58	.56		
SARCINA WITHIN EXPECT(2)	.87	2	.44	.77	.467

Constatăm că efectul simplu al sarcinii în condiție de expectanțe scăzute este semnificativ [$F(2,58) = 10,56$, $p = 0,000$], iar efectul simplu al sarcinii în condiție de expectanțe ridicate este nesemnificativ [$F(2,58) = 0,77$, $p = 0,476$]. Știm astfel că există diferențe semnificative între mediile $M1$, $M3$ și $M5$. Urmează să verificăm prin comparații simple perechile de medii care ne interesează. Vom folosi *contraste ortogonale* (deoarece sintaxa este similară cu cea de la designurile intergrupuri, în cazul contrastelor nonortogonale sintaxa fiind mult mai complicată).

Pentru efectul simplu al sarcinii în condiția de expectanțe scăzute, vom compara condițiile *sarcină_medie* – *sarcină_dificilă* ($M3$ cu $M5$), iar coeficienții de contrast vor fi $(01-1)$; deoarece trebuie să analizăm $(k-1)$ contraste, iar setul trebuie să fie ortogonal, vom mai crea un contrast chiar dacă acesta nu ne va interesa în analiză: $(2-1-1)$. Sintaxa va fi următoarea:

```
MANOVA sle1 sle2 s2e1 s2e2 s3e1 s3e2
/WSFACTORS=sarcina(3) expect(2)
/PRINT=SIGNIF(AVONLY)
/CONTRAST(sarcina)=SPECIAL (1 1 1, 0 1 -1, 2 -1 -1)
/WSDESIGN=sarcina(1) WITHIN expect(1).
```



Dacă ne-ar fi interesat și rezultatele celui de-al doilea contrast, am fi scris în sintaxă subcomanda :

„WDESIGN” : sarcina(1) WITHIN expect(1), sarcina(2) WITHIN expect(1).

Prezentăm mai jos rezultatele relevante.

Tests involving 'SARCINA(1) WITHIN EXPECT(1)' Within-Subject Effect.

AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares

Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	16.73	29	.58		
SARCINA(1) WITHIN EXPECT(1)	7.22	1	7.22	12.52	.001

Observăm că există diferențe semnificative între M3 și M5 [$F(1, 29) = 12,52$, $p = 0,001$] (rezultatul este identic cu cel obținut prin testul t).

b) Analiza efectelor simple ale variabilei expectanțe

Analiza efectelor simple ale VI *expect* în fiecare dintre condițiile VI *sarcina* se realizează prin următoarea sintaxă :

```
MANOVA sle1 sle2 s2e1 s2e2 s3e1 s3e2
/WSFACTORS=sarcina(3) expect(2)
/PRINT=SIGNIF(AVONLY)
/WSDESIGN=expect WITHIN sarcina(1), expect WITHIN sarcina(2),
expect WITHIN sarcina(3).
```



```
Syntax1 - SPSS Syntax Editor
File Edit View Analyze Graphs Utilities Run Window Help
[Icons]
MANOVA s1e1 s1e2 s2e1 s2e2 s3e1 s3e2
/WSFACTORS=sarcina(3) expect(2)
/PRINT=SIGNIF(AVONLY)
/WSDESIGN=expect WITHIN sarcina(1), expect WITHIN sarcina(2), expect WITHIN sarcina(3).
```

Rezultatele relevante sunt prezentate mai jos. Observăm că efectul simplu al VI *expectanțe* în condiția *sarcină ușoară* [sarcina(1)] este nesemnificativ [F (1, 29) = 0,17, p = 0,681], efectul VI *expectanțe* în condiția *sarcină medie* este nesemnificativ [F (1, 29) = 3,48, p = 0,072], în schimb efectul VI *expectanțe* în condiția de *sarcină dificilă* este semnificativ [F (1, 29) = 14,36, p = 0,001]. Așadar, nivelul expectanței are efecte asupra performanței în sarcină doar atunci când sarcina este dificilă, un nivel ridicat al expectanțelor conducând la performanțe semnificativ mai mari comparativ cu nivelul scăzut al expectanțelor.

Tests involving 'EXPECT WITHIN SARCINA(1)' Within-Subject Effect.					
AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	18.50	29	.64		
EXPECT WITHIN SARCINA(1)	.11	1	.11	.17	.681


Tests involving 'EXPECT WITHIN SARCINA(2)' Within-Subject Effect.					
AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	17.53	29	.60		
EXPECT WITHIN SARCINA(2)	2.11	1	2.11	3.48	.072

Tests involving 'EXPECT WITHIN SARCINA(3)' Within-Subject Effect.					
AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	21.02	29	.72		
EXPECT WITHIN SARCINA(3)	10.41	1	10.41	14.36	.001

16.4.2. Analiza contrastelor de interacțiune

Vom realiza analiza contrastelor de interacțiune prin intermediul sintaxelor. Și în cazul acestei analize putem folosi contraste ortogonale sau nonortogonale (însă în cazul unei VI întragrupuri, contrastele nonortogonale necesită anumite transformări și sunt mai complicate). Vom descrie doar contrastele de interacțiune ortogonale. Să analizăm dacă diferența dintre mediile M1 și M5 este semnificativ distinctă de diferența dintre mediile M2 și M6: $[(M1 - M5) \neq (M2 - M6)]$, ceea ce e echivalent cu a verifica dacă $[(M1 - M2) \neq (M5 - M6)]$. Pentru VI sarcina vom avea un contrast între condițiile sarcină scăzută și sarcină ridicată (coeficienții sunt 1 0 -1); vom crea și al doilea contrast (doar formal, deoarece nu ne va interesa în analiză), regula fiind să avem $k - 1 (= 2)$ contraste. Sintaxa va fi următoarea (atenție, contrastul trebuie să fie ortogonal, altfel rezultatele conțin erori):

```
MANOVA s1e1 s1e2 s2e1 s2e2 s3e1 s3e2
/WSFACTORS=sarcina(3) expect(2)
/PRINT=SIGNIF(AVONLY)
/CONTRAST(sarcina)=SPECIAL (1 1 1, 1 0 -1, 1 -2 1)
/WSDESIGN=sarcina(1) BY expect.
```



Rezultatele relevante sunt prezentate în continuare:

Tests involving 'SARCINA(1) BY EXPECT' Within-Subject Effect.

AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	16.85	29	.58		
SARCINA(1) BY EXPECT	4.19	1	4.19	7.21	.012

Observăm că acest contrast de interacțiune este semnificativ [$F(1, 29) = 7.21, p = 0.012$] (rezultat identic cu cel obținut prin testul de contrast în cazul interacțiunii, vezi tabelul *Tests of Within-Subjects Contrasts*), prin urmare manipularea experimentală sarcină ^{ușoară-dificilă} are un efect semnificativ mai puternic în condiția de expectanțe ridicate decât în condiția de expectanțe scăzute.

Dacă ambele VI ar fi avut mai mult de două nivele, atunci am fi putut testa un contrast de interacțiune de tipul $S_{\text{contrast}} \times E_{\text{contrast}}$, definind mai întâi contrastele ortogonale pentru fiecare factor și apoi, în cadrul subcomandei „/WSDESIGN” specificând, de exemplu, „expect(1) BY sarcina(2)”, numerele din paranteză făcând referire la numărul contrastului fiecărui factor. În cazul unui design cu trei VI, lucrurile ar fi ceva mai complicate și nu vom insista aici, mai ales că designurile cu măsurători repetate conținând trei VI sunt extrem de rare.

16.5. Calcularea mărimii efectelor

Mărimia efectelor în cazul contrastelor se calculează cu ajutorul formulei :

$$r = \frac{\sqrt{\frac{F(1, df_R)}{F(1, df_R) + df_R}}}{\sqrt{t^2 + df_{\text{eroare}}}} = \frac{t}{\sqrt{t^2 + df_{\text{eroare}}}}$$

În cazul efectului principal al variabilei *sarcina* analizat prin testele post hoc Bonferroni, indicatorii mărimii efectelor pentru rezultatele semnificative statistic sunt :

$$r_{\text{sarcina 1-sarcina 3}} = \frac{3,50}{\sqrt{12,25 + 29}} = 0,55$$

$$r_{\text{sarcina 2-sarcina 3}} = \frac{3,35}{\sqrt{11,22 + 29}} = 0,53$$

În ceea ce privește efectul principal al variabilei *expectanțe*, mărimea efectului va fi :

$$r_{\text{expect 2 - expect 1}} = 0,52$$

În cazul testelor de contrast realizate pentru variabila *sarcină*, rezultatele sunt similare celor obținute prin teste post hoc, iar mărimea efectelor va fi aceeași. Ceea ce este important în cazul ANOVA factorială cu măsurători repetate este că testele de contrast analizează și interacțiunea dintre variabilele *sarcina* și *expectanțe*, fiind vorba despre contraste de interacțiune; contrastul de interacțiune semnificativ statistic este cel care compară diferența dintre condițiile (expectanțe scăzute-ridicate) ^{sarcină ușoră} cu diferența dintre condițiile (expectanțe scăzute-ridicate) ^{sarcină dificilă} [$F(1, 29) = 7,209$, $p = 0,012$]; acest contrast de interacțiune este specific analizei efectelor de interacțiune.

Mărimea efectului în cazul acestui contrast de interacțiune va fi :

$$r_{\text{s. usoara vs dificila, e scazute vs ridicate}} = \sqrt{\frac{7,209}{7,209 + 29}} = 0,45$$

În cazul efectului de interacțiune analizat prin intermediul efectelor simple, ne vom referi doar la efectele simple ale variabilei *expectanțe*; cum există un singur efect simplu

semnificativ al variabilei *expectanțe* în condiția de *sarcină dificilă* [$F(1, 29) = 14,36$, $p = 0,001$], mărimea acestui efect este :

$$r_{(sarcina\_dificila)} = \sqrt{\frac{14,36}{14,36 + 29}} = 0,57$$

16.6. Prezentarea rezultatelor

Conform rezultatelor obținute, există un efect principal semnificativ al variabilei *expectanțe* asupra variabilei *performanță* și de asemenea există un efect principal semnificativ al variabilei *sarcină* asupra variabilei *performanță*. Totodată, se observă un efect de interacțiune semnificativ statistic al variabilelor *expectanțe* și *sarcină* asupra variabilei *performanță* (tabelul 16.3). Tabelul 16.4 prezintă mediile, abaterile standard și numărul de subiecți în ceea ce privește variabila *performanță* pentru fiecare condiție experimentală.

Tabelul 16.3. Tabelul ANOVA factorială pentru *performanță* în funcție de *expect* și *sarcină*

Variabile și sursa dispersie	SS	df	MS	F	p
Expectanțe	8,36	1	8,36	10,47	0,003
Eroare (expectanțe)	23,17	29	0,80		
Sarcină	8,34	2	4,17	7,78	0,001
Eroare (sarcină)	31,08	58	0,54		
Expectanțe × Sarcină	4,26	2	2,13	3,64	0,032
Expectanțe					
Sarcină ușoară	0,11	1	0,11	,17	0,681
Sarcină medie	2,11	1	2,11	3,48	0,072
Sarcină dificilă	10,41	1	10,41	14,36	0,001
Eroare (expectanțe × sarcină)	33,87	58	0,58		

Tabel 16.4. Mediile, deviațiile standard și loturile de subiecți pentru *performanță* în funcție de *expect* și *sarcină*

Sarcină	Expectanțe scăzute			Expectanțe ridicate		
	M	SD	n	M	SD	n
ușoară	8,63	0,62	30	8,71	0,82	30
medie	8,50	0,87	30	8,88	0,73	30
ridică	7,81	0,78	30	8,64	0,82	30

Analiza efectelor simple ale variabilei *expect* evidențiază existența doar a unui efect simplu semnificativ, în condiția de *sarcină dificilă* [$F(1, 29) = 14,36$, $p = 0,001$, $r = 0,57$]. Așadar, nivelul expectanței are un efect puternic asupra performanței în cazul sarcinilor dificile, un nivel ridicat al expectanțelor conducând la performanțe superioare.

Capitolul 17. ANOVA mixtă

17.1. Prezentare generală

Denumită în engleză *ANOVA mixed* (sau *split-plot*), această metodă este o combinație între ANOVA cu măsurători repetate și ANOVA factorială (grupe independente) și se aplică în cazul designurilor mixte care conțin cel puțin o VI intergrupuri și cel puțin o VI intragrupuri. Distribuția scorurilor într-un astfel de design în care variabila sarcina este intergrupuri, iar variabila expectanțe este intragrupuri ar arăta astfel :

Tabel 17.1. Design 2 × 3 ANOVA mixtă

Subiecții (grupul 1)	Sarcină ușoară		Subiecții (grupul 2)	Sarcină medie		Subiecții (grupul 3)	Sarcina dificilă	
	Expect. scăzute	Expect. ridicate		Expect. scăzute	Expect. ridicate		Expect. scăzute	Expect. ridicate
1	8,30	9,36	31	8,30	8,53	61	7,53	9,52
2	8,91	9,52	32	8,80	9,82	62	9,46	9,64
3	9,14	9,70	33	8,81	9,00	63	9,88	7,76
...	...	...	...	...	...	...	...	...
30	8,90	9,64	60	8,75	9,35	90	8,80	9,82


Condițiile aplicării metodei ANOVA mixte sunt :

1. VD cantitativă și normal distribuită ;
2. condiția de simetrie complexă, care presupune egalitatea varianțelor pentru VI intergrupuri și egalitatea covarianțelor VI intragrupuri de-a lungul tuturor treptelor VI intergrupuri – corelațiile dintre fiecare două condiții experimentale sunt egale (egalitatea covarianțelor în acest caz presupune o sfericitate care ia în calcul toate treptele VI intergrupuri). Condiția de simetrie complexă este verificată prin intermediul testului M Box ; dacă acesta este nesemnificativ statistic, condiția de simetrie complexă este îndeplinită.

17.2. Aplicarea metodei ANOVA mixtă

Să analizăm influența dificultății sarcinii (ușoară, medie și dificilă) și a nivelului expectanțelor de reușită în sarcină (ridicat și scăzut) asupra performanței în sarcină. VI sarcina este intergrupuri, iar VI expectanțe este intragrupuri (tabelul 17.1). Avem trei grupe de subiecți corespunzând celor trei tipuri de sarcină. Fiecare astfel de grup va fi supus la două manipulări experimentale: inducerea unui nivel de expectanțe ridicat sau scăzut de reușită înainte de implicarea în sarcina respectivă.

Deschidem fișierul *ANOVA mixta*. Calea în SPSS este: *Analyze* → *General Linear Model* → *Repeated Measures*. În câmpul *Within-Subject Factor Name* ștergem Factor1 și trecem *expect*, apoi în câmpul *Number of Leves* trecem „2” (numărul de categorii ale acestei VI), apoi clic *Add* și clic *Define*. În câmpul *Within-Subjects Variables* trecem în ordine *expect 1* și *expect 2*, apoi în câmpul *Between-Subjects Factor* trecem variabila *sarcina*.



Apăsăm butonul *Options* și în caseta de dialog bifăm opțiunea *Homogeneity tests* (pentru calcularea testului F Levene și M Box) și *Descriptive statistics*, trecem variabilele independente *sarcina* și *expectanțe* în câmpul din dreapta *Display Means for*, aici activăm opțiunea *Compare main effects*, iar din câmpul *Confidence interval adjustment* selectăm testul *Bonferroni* pentru analiza efectelor principale, apoi clic *Continue*.

Repeated Measures: Options

Estimated Marginal Means

Factor(s) and Factor Interactions:

(OVERALL)
sarcina
expect
sarcina*expect

Display Means for:

expect
sarcina

☒ Compare main effects

Confidence interval adjustment:

Bonferroni

Display

☒ Descriptive statistics
☐ Estimates of effect size
☐ Observed power
☐ Parameter estimates
☐ SSCP matrices
☐ Residual SSCP matrix

☐ Transformation matrix
☒ Homogeneity tests
☐ Spread vs. level plots
☐ Residual plots
☐ Lack of fit test
☐ General estimable function

Significance level: .05 Confidence intervals are 95%

Continue Cancel Help

Graficul se realizează similar metodelor ANOVA anterioare. Pentru efectul de interacțiune, trecem variabila *sarcina* în câmpul *Horizontal Axis*, iar variabila *expectanțe* în câmpul *Separate Lines*, clic pe butonul *Add*; apoi trecem variabila *sarcina* în câmpul *Horizontal Axis* și clic *Add*, iar în final trecem variabila *expectanțe* în câmpul *Horizontal Axis*, clic *Add*, clic *Continue* și clic *OK*.

Repeated Measures: Profile Plots

Factors:

sarcina
expect

Horizontal Axis:

Continue

Cancel

Help

Separate Lines:

Separate Plots:

Plots: Add Change Remove

sarcina*expect
sarcina
expect

17.3. Interpretarea outputului

Tabelul *Descriptive Statistics* prezintă mediile, abaterile standard și numărul de subiecți pentru fiecare condiție experimentală.

Descriptive Statistics				
	sarcina	Mean	Std. Deviation	N
expectante scazute	sarcina usoara	8,6317	,6235	30
	sarcina medie	8,5040	,8753	30
	sarcina dificila	7,8100	,7806	30
	Total	8,3152	,8406	90
expectante ridicate	sarcina usoara	8,7173	,8257	30
	sarcina medie	8,8787	,7293	30
	sarcina dificila	8,6430	,8198	30
	Total	8,7463	,7901	90

În tabelul *Box's Test of Equality of Covariance Matrices* este prezentat rezultatul la testele de verificare a condiției de simetrie complexă, $\text{Box } M = 5,147$, $p = 0,547$, prin urmare, condiția de simetrie complexă este îndeplinită.

Box's Test of Equality of Covariance Matrices

Box's M	5,147
F	,829
df1	6
df2	188642,8
Sig.	,547

Tests the null hypothesis that the observed covariance matrices of the dependent variables are equal across groups.

a.

Design: Intercept+SARCINA

Within Subjects Design: EXPECT

Dacă vom urmări rezultatele la testele Levene de omogenitate a varianțelor și rezultatele la testul Mauchly de sfericitate vom observa că și acestea sunt nesemnificative, fapt ce confirmă rezultatele la testul M Box.

Levene's Test of Equality of Error Variances

	F	df1	df2	Sig.
expectante scazute	1,187	2	87	,310
expectante ridicate	,189	2	87	,828

Tests the null hypothesis that the error variance of the dependent variable is equal across groups.

a.

Design: Intercept+SARCINA

Within Subjects Design: EXPECT

Mauchly's Test of Sphericity^b

Measure: MEASURE_1

Within Subjects Effect	Mauchly's W	Approx. Chi-Square	df	Sig.	Epsilon ^a		
					Greenhouse-Geisser	Huynh-Feldt	Lower-bound
EXPECT	1,000	,000	0	.	1,000	1,000	1,000

Tests the null hypothesis that the error covariance matrix of the orthonormalized transformed dependent variables is proportional to an identity matrix.

- a. May be used to adjust the degrees of freedom for the averaged tests of significance. Corrected tests are displayed in the Tests of Within-Subjects Effects table.

b.

Design: Intercept+SARCINA

Within Subjects Design: EXPECT

Din tabelul *Tests of Within-Subjects Effects* observăm că există un efect principal al variabilei *expectanțe* [$F(1, 87) = 12,757, p = 0,001$] și, de asemenea, un efect de interacțiune al variabilelor *expectanțe* * *sarcina* [$F(2, 87) = 3,249, p = 0,044$] semnificativ.

Tests of Within-Subjects Effects

Measure: MEASURE_1

Source		Type III Sum of Squares	df	Mean Square	F	Sig.
EXPECT	Sphericity Assumed	8,364	1	8,364	12,757	,001
	Greenhouse-Geisser	8,364	1,000	8,364	12,757	,001
	Huynh-Feldt	8,364	1,000	8,364	12,757	,001
	Lower-bound	8,364	1,000	8,364	12,757	,001
EXPECT * SARCINA	Sphericity Assumed	4,260	2	2,130	3,249	,044
	Greenhouse-Geisser	4,260	2,000	2,130	3,249	,044
	Huynh-Feldt	4,260	2,000	2,130	3,249	,044
	Lower-bound	4,260	2,000	2,130	3,249	,044
Error(EXPECT)	Sphericity Assumed	57,039	87	,656		
	Greenhouse-Geisser	57,039	87,000	,656		
	Huynh-Feldt	57,039	87,000	,656		
	Lower-bound	57,039	87,000	,656		

Din tabelul *Tests of Between-Subjects Effects* observăm că și efectul principal al variabilei *sarcina* este semnificativ [$F(2, 87) = 7,434, p = 0,001$].

Tests of Between-Subjects Effects

Measure: MEASURE_1

Transformed Variable: Average

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Intercept	13099.351	1	13099.351	23350.554	.000
SARCINA	8.341	2	4.171	7.434	.001
Error	48.806	87	.561		

17.4. Analiza efectelor principale

Analiza efectului principal al variabilei independente intragrupuri – *expectanțe* – se poate face pe trei căi: 1) prin teste t pentru eșantioane perechi, 2) prin teste de contrast și 3) prin selectarea testului Bonferroni din câmpul *Compare main effects*, butonul *Options*.

Deoarece am ales varianta a treia, rezultatele se regăsesc în tabelul *Pairwise Comparisons* de mai jos. Cum rezultatele la testul Bonferroni sunt semnificative rezultă că există diferențe semnificative între condiția de expectanțe scăzute și cea de expectanțe ridicate [Bonferroni $t = 3,56 (= 0,431/0,121)$, $p = 0,001$], subiecții obținând performanțe mai mari în condiția de expectanțe ridicate indiferent de influența variabilei *sarcina*.

Pairwise Comparisons

Measure: MEASURE_1


(I) EXPECT	(J) EXPECT	Mean Difference (I-J)	Std. Error	Sig. ^a	95% Confidence Interval for Difference ^a	
					Lower Bound	Upper Bound
1	2	-.431*	.121	.001	-.671	-.191
2	1	.431*	.121	.001	.191	.671

Based on estimated marginal means

*. The mean difference is significant at the .05 level.

a. Adjustment for multiple comparisons: Bonferroni.

Efectul principal al variabilei expectanțe este prezentat grafic în continuare.



În ceea ce privește efectul principal al variabilei independente intergrupuri, acesta poate fi analizat prin: 1) teste de contrast, 2) teste post hoc (selectate prin activarea butonului *Post hoc*, pentru VI cu mai mult de două nivele) și 3) testul Bonferroni (selectat din câmpul *Compare main effects*, butonul *Options*).

Rezultatele la testul Bonferroni din tabelul *Pairwise Comparisons* evidențiază faptul că există diferențe semnificative între condițiile sarcină ușoară/dificilă [Bonferroni $t = 3,27$, $p = 0,001$] și sarcină medie/dificilă [Bonferroni $t = 3,39$, $p = 0,001$] și nu există diferențe semnificative între condițiile sarcină ușoară/medie [Bonferroni $t = 0,01$, $p = 1,000$]; prin urmare, subiecții obțin performanțe semnificativ mai mari în sarcini ușoare și de dificultate medie, comparativ cu sarcinile dificile, indiferent de influența variabilei *expect*.

Pairwise Comparisons

Measure: MEASURE_1


(I) sarcina	(J) sarcina	Mean Difference (I-J)	Std. Error	Sig. ^a	95% Confidence Interval for Difference ^a	
					Lower Bound	Upper Bound
sarcina usoara	sarcina medie	-1,683E-02	,137	1,000	-,351	,317
	sarcina dificila	,448*	,137	,005	,114	,782
sarcina medie	sarcina usoara	1,683E-02	,137	1,000	-,317	,351
	sarcina dificila	,465*	,137	,003	,131	,799
sarcina dificila	sarcina usoara	-,448*	,137	,005	-,782	-,114
	sarcina medie	-,465*	,137	,003	-,799	-,131

Based on estimated marginal means

*. The mean difference is significant at the ,05 level.

a. Adjustment for multiple comparisons: Bonferroni.

Efectul principal al variabilei sarcină este prezentat grafic în continuare.




17.5. Analiza efectului de interacțiune

Deoarece efectul de interacțiune este semnificativ, prioritară este interpretarea acestuia, și nu a efectelor principale. Și aici analiza efectului de interacțiune se poate face apelând la cele două demersuri: analiza efectelor simple și analiza contrastelor de interacțiune.

17.5.1. Analiza efectului de interacțiune prin intermediul efectelor simple

Analiza efectelor simple se realizează studiind efectul unei VI în fiecare dintre condițiile celeilalte VI. Prezentăm mai jos graficul efectului de interacțiune.



17.5.1.1. Analiza efectelor simple prin teste t

Analiza efectelor simple ale VI intergrupuri sarcina asupra performanței în condițiile de expectanțe scăzute/ridicate se poate face prin:

1. teste t pentru eșantioane independente (ajustând pragul de semnificație);
2. tehnica One-Way ANOVA (cu testele a priori sau post hoc respective), în care VI va fi variabila sarcina, iar VD vor fi variabilele *expect1* și *expect2*;
3. folosirea sintaxelor.

Vom folosi mai întâi tehnica One-Way ANOVA cu teste post hoc (alegem testul Bonferroni). Rezultatele se prezintă astfel:

1. există un efect simplu al sarcinii asupra performanțelor în condiție de expectanțe scăzute, $F(2, 89) = 9,974$, $p = 0,000$ (tabelul ANOVA); analizând rezultatele la testul Bonferroni (tabelul Multiple Comparisons), observăm că există diferențe semnificative între condițiile sarcină ușoară și sarcină dificilă, Bonferroni $t = 4,15$ ($= 0,8217/0,198$), $p = 0,000$ și între condițiile sarcină medie și sarcină dificilă, Bonferroni $t = 3,505$, $p = 0,002$;
2. nu există un efect simplu al sarcinii asupra performanțelor în condiție de expectanțe ridicate, $F(2, 89) = 0,693$, $p = 0,503$ (tabelul ANOVA).

ANOVA

		Sum of Squares	df	Mean Square	F	Sig.
expectante scăzute	Between Groups	11,731	2	5,865	9,974	,000
	Within Groups	51,163	87	,588		
	Total	62,893	89			
expectante ridicate	Between Groups	,871	2	,435	,693	,503
	Within Groups	54,682	87	,629		
	Total	55,553	89			

Multiple Comparisons

Bonferroni


Dependent Variable	(I) sarcina	(J) sarcina	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval	
						Lower Bound	Upper Bound
expectante scăzute	sarcina usoara	sarcina medie	,1277	,1980	1,000	-,3557	,6110
		sarcina dificila	,8217*	,1980	,000	,3383	1,3050
	sarcina medie	sarcina usoara	-,1277	,1980	1,000	-,6110	,3557
		sarcina dificila	,6940*	,1980	,002	,2106	1,1774
	sarcina dificila	sarcina usoara	-,8217*	,1980	,000	-1,3050	-,3383
		sarcina medie	-,6940*	,1980	,002	-1,1774	-,2106
expectante ridicate	sarcina usoara	sarcina medie	-,1613	,2047	1,000	-,6610	,3384
		sarcina dificila	7,433E-02	,2047	1,000	-,4254	,5740
	sarcina medie	sarcina usoara	,1613	,2047	1,000	-,3384	,6610
		sarcina dificila	,2357	,2047	,758	-,2640	,7354
	sarcina dificila	sarcina usoara	-7,4333E-02	,2047	1,000	-,5740	,4254
		sarcina medie	-,2357	,2047	,758	-,7354	,2640

*. The mean difference is significant at the .05 level.


Analiza efectelor simple ale VI intragrupuri expectanțe asupra performanței în condițiile de sarcină ușoară, medie sau dificilă se poate face prin :

1. împărțirea bazei de date după VI intergrupuri (comanda *Split File*) ;
2. folosirea sintaxelor.

Folosind tehnica împărțirii bazei de date după VI sarcină, în meniul *Data* → *Split File* activăm opțiunea *Organize output by groups*, trecem variabila *sarcina* în câmpul *Group based on* și clic *OK*.



În continuare aplicăm teste t pentru eșantioane perechi.



Rezultatele obținute sunt prezentate și analizate continuare.

- Efectul simplu al variabilei *expectanțe* în condiția de *sarcină ușoară* nu este semnificativ [$t(29) = 0,415$, $p = 0,681$].

Paired Samples Test^a

		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	expectante scazute - expectante ridicate	-8,6E-02	1,1294	,2062	-,5074	,3361	-,415	29	,681

a. sarcina = sarcina usoara

- Efectul simplu al variabilei *expectanțe* în condiția de *sarcină medie* nu este semnificativ [t (29) = 1,867, p = 0,072].

Paired Samples Test^a

		Paired Differences				t	df	Sig. (2-tailed)	
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower				Upper
Pair 1	expectante scazute - expectante ridicate	-,3747	1,0994	,2007	-,7852	,0359	-1,867	29	,072

a. sarcina = sarcina medie

- Efectul simplu al variabilei *expectanțe* în condiția de *sarcină dificilă* este semnificativ [t (29) = 3,790, p = 0,001].

Paired Samples Test^a

		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	expectante scazute - expectante ridicate	-,8330	1,2039	,2198	-1,283	-,3835	-3,790	29	,001


a. sarcina = sarcina dificila

17.5.1.2. Analiza efectelor simple prin folosirea sintaxelor

Ne asigurăm mai întâi că în meniul *Data* → *Split File* am anulat comanda prin intermediul butonului *Reset*. Să analizăm mai întâi efectele simple ale VI intergrupuri [*sarcina*] pentru fiecare nivel al VI intragrupuri.

Sintaxa va fi următoarea :


```
MANOVA expect1 expect2 BY sarcina(1,3)
/WSFACTORS=expect(2)
/WSDESIGN=MWITHIN expect(1), MWITHIN expect(2)
/DESIGN=sarcina.
```



Am folosit expresia „MWITHIN” în loc de „WITHIN” în dreptul comenzii „WSDESIGN”. Vom folosi aceeași expresie și când vom apela la comanda „DESIGN” pentru calcularea efectelor simple ale VI *expectanțe* la fiecare nivel al VI *sarcina* (vom vedea mai jos). Rezultatele sunt următoarele:

Tests involving 'MWITHIN EXPECT(1)' Within-Subject Effect.

Tests of Significance for T1 using UNIQUE sums of squares

Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	51.16	87	.59		
MWITHIN EXPECT(1)	6222.86	1	6222.86	10581.71	.000
SARCINA BY MWITHIN EXPECT(1)	11.73	2	5.87	9.97	.000

Tests involving 'MWITHIN EXPECT(2)' Within-Subject Effect.

Tests of Significance for T2 using UNIQUE sums of squares


Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	54.68	87	.63		
MWITHIN EXPECT(2)	6884.85	1	6884.85	10953.84	.000
SARCINA BY MWITHIN EXPECT(2)	.87	2	.44	.69	.503

În designurile mixte, efectele simple sunt prezentate de MANOVA puțin diferit: de exemplu, în loc de „SARCINA WITHIN EXPECT(1)” se scrie „SARCINA BY MWITHIN EXPECT(1)”. Observăm că există un efect simplu semnificativ al VI *sarcina* în condiția

de *expectanțe scăzute* [EXPECT(1)], $F(2, 87) = 9,97$, $p = 0,000$, ceea ce înseamnă că există diferențe între mediile condițiilor sarcină ușoară, medie și ridicată, în interiorul condiției de expectanțe scăzute (nu știm exact între care condiții ale sarcinii, dar vom afla prin intermediul *comparațiilor simple* mai jos). De asemenea, nu există un efect simplu semnificativ al VI sarcina în condiția de *expectanțe ridicate*, $F(2, 87) = 0,69$, $p = 0,503$. Rezultatele sunt identice cu cele ale testelor F omnibus din tabelul ANOVA anterior.

Prin tehnica *comparațiilor simple* putem verifica, în cazul unui efect simplu semnificativ, între care condiții sunt semnificative diferențele. De exemplu, pentru efectul simplu al sarcinii în condiția expectanțelor scăzute, vom verifica dacă există diferențe semnificative între condițiile sarcină ușoară versus sarcină dificilă și sarcină medie versus sarcină dificilă. Sintaxa este următoarea :

```
MANOVA expect1 expect2 BY sarcina(1,3)
/WSFACTORS=expect(2)
/PRINT=SIGNIF(AVONLY)
/CONTRAST(sarcina)=SPECIAL(1 1 1, 1 0 -1, 0 1 -1)
/WSDESIGN=MWITHIN expect(1)
/DESIGN=sarcina(1) sarcina(2).
```



Am precizat contrastele pentru VI sarcina (fiind o variabilă intergrupuri, se pot folosi fără complicații contraste nonortogonale). Subcomanda „WSDESIGN” precizează nivelul VI expectanțe asupra căruia vor fi realizate contrastele (primul nivel, în acest caz). În dreptul subcomenzii „DESIGN” trebuie precizate toate contrastele dacă acestea sunt nonortogonale (cazul nostru); dacă contrastele sunt ortogonale, atunci le putem preciza doar pe cele care ne interesează, specificând în schimb și subcomanda „ERROR=WITHIN”. Rezultatele relevante sunt următoarele :

Tests involving 'MWITHIN EXPECT(1)' Within-Subject Effect.

AVERAGED Tests of Significance for EXPECT using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	51.16	87	.59		
MWITHIN EXPECT(1)	6222.86	1	6222.86	10581.71	.000
SÂRCINA(1) BY MWITHIN EXPECT(1)	10.13	1	10.13	17.22	.000
SARCINA(2) BY MWITHIN EXPECT(1)	7.22	1	7.22	12.29	.001

Observăm că (fiind în condiția de expectanțe scăzute) există diferențe semnificative între condițiile sarcină ușoară *versus* sarcină dificilă [$F(1, 87) = 17,22, p = 0,000$] și de asemenea între condițiile sarcină medie *versus* sarcină dificilă [$F(1, 87) = 12,29, p = 0,001$].

Vom analiza acum efectele simple ale VI intragrupuri [*expectanțe*] la fiecare nivel al VI intergrupuri. Sintaxa va fi următoarea:

```
MANOVA expect1 expect2 BY sarcina(1,3)
/WSFACTORS=expect(2)
/PRINT = SIGNIF (AVONLY)
/WSDESIGN=expect
/DESIGN =MWITHIN sarcina(1), MWITHIN sarcina(2), MWITHIN sarcina(3).
```

Syntax1 - SPSS Syntax Editor

File Edit View Analyze Graphs Utilities Run Window Help



```
MANOVA expect1 expect2 BY sarcina(1,3)
```

```
/WSFACTORS=expect(2)
```

```
/PRINT = SIGNIF (AVONLY)
```

```
/WSDESIGN=expect
```

```
/DESIGN =MWITHIN sarcina(1), MWITHIN sarcina(2), MWITHIN sarcina(3).
```

Ordinea în sintaxă prevede ca subcomanda „WSDESIGN” să fie întotdeauna prima, urmată de subcomanda „DESIGN”. Așadar, am precizat că ne interesează efectele variabilei *expect* în cadrul fiecărei condiții (1, 2 și 3) ale variabilei *sarcina*. Comparând sintaxa cu cea precedentă, observăm că, atunci când intenționăm să analizăm efectele simple ale variabilei intergrupuri, expresia „MWITHIN” este prezentă în subcomanda „WSDESIGN”, iar în cazul efectelor simple ale variabilei intragrupuri, expresia „MWITHIN” este folosită în subcomanda „DESIGN”. Rezultatele relevante sunt prezentate în continuare:

Tests involving 'EXPECT' Within-Subject Effect.					
AVERAGED Tests of Significance for EXPECT using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	57.04	87	.66		
MWITHIN SARCINA(1) BY EXPECT	.11	1	.11	.17	.683
MWITHIN SARCINA(2) BY EXPECT	2.11	1	2.11	3.21	.077
MWITHIN SARCINA(3) BY EXPECT	10.41	1	10.41	15.88	.000

Constatăm că doar efectul simplu al variabilei *expectanțe* în condiția de *sarcină dificilă* [SARCINA(3)] este semnificativ [$F(1, 87) = 15,88, p = 0,000$].

17.5.2. Analiza efectului de interacțiune prin intermediul contrastelor

Vom folosi sintaxele, comparând diferența dintre două nivele (sau o medie a acestora) ale unei VI în cadrul a două nivele ale altei VI.

Dacă cele două VI sunt *factorA* și *factorB*, ambele cu mai mult de două nivele, putem analiza două tipuri de contraste de interacțiune :

1. $A_{\text{contrast}} \times B$ sau $A \times B_{\text{contrast}}$, atunci când contrastele sunt specificate doar pentru una dintre variabile (*A* în primul caz și *B* în al doilea). Pentru primul caz, un exemplu ar fi „FACTA(1) BY FACTB”, iar pentru cazul al doilea un exemplu ar fi „FACTB(1) BY FACTA”.
2. $A_{\text{contrast}} \times B_{\text{contrast}}$, atunci când sunt specificate contraste pentru ambele variabile. Un exemplu ar fi „FACTA(1) BY FACTB(1)”.


Aplicație. Într-un studiu asupra excelenței intelectuale ne propunem să analizăm dacă impactul în timp al unui training centrat pe dezvoltarea inteligenței emoționale este mai puternic în cazul elevilor superior dotați decât în cazul elevilor mediu dotați.

Vom măsura inteligența emoțională a subiecților înainte de intervenție (pretest), apoi imediat după intervenție (posttest1) și la trei luni după intervenție (posttest2). Variabilele independente sunt *grup* (variabilă intergrupuri) și *moment* (variabilă intragrupuri), iar variabila dependentă este *inteligența emoțională*. *Ne propunem să analizăm dacă efectele în timp ale trainingului sunt mai puternice la elevii superior dotați comparativ cu elevii mediu dotați.*

Tabel 17.2. Designul cercetării 2 × 3 ANOVA mixtă

		Momentul testării		
		înainte de training (pretest)	imediat după training (posttest1)	la trei luni după training (posttest2)
Grup	superior dotați	G1 (M1)	G3 (M3)	G5 (M5)
	mediu dotați	G2 (M2)	G4 (M4)	G6 (M6)

Deschidem fișierul *ANOVA_mixta_2*. Efectul de interacțiune este prezentat grafic mai jos.



Rezultatele principale obținute în urma aplicării ANOVA mixtă sunt prezentate și discutate mai jos. Analizând rezultatele din tabelul *Tests of Within-Subjects Effects* constatăm că :

- efectul principal al variabilei *moment* asupra variabilei *inteligență emoțională* este semnificativ [$F(2, 116) = 21,898, p = 0,000$];
- efectul de interacțiune al variabilelor *moment* și *grup* asupra variabilei *inteligență emoțională* este semnificativ [$F(2, 116) = 3,436, p = 0,035$].

Tests of Within-Subjects Effects

Measure: MEASURE_1

Source		Type III Sum of Squares	df	Mean Square	F	Sig.
MOMENT	Sphericity Assumed	23,513	2	11,756	21,898	,000
	Greenhouse-Geisser	23,513	1,867	12,592	21,898	,000
	Huynh-Feldt	23,513	1,960	11,994	21,898	,000
	Lower-bound	23,513	1,000	23,513	21,898	,000
MOMENT * GRUP	Sphericity Assumed	3,690	2	1,845	3,436	,035
	Greenhouse-Geisser	3,690	1,867	1,976	3,436	,039
	Huynh-Feldt	3,690	1,960	1,882	3,436	,036
	Lower-bound	3,690	1,000	3,690	3,436	,069
Error(MOMENT)	Sphericity Assumed	62,278	116	,537		
	Greenhouse-Geisser	62,278	108,304	,575		
	Huynh-Feldt	62,278	113,699	,548		
	Lower-bound	62,278	58,000	1,074		

Conform rezultatelor prezentate în tabelul *Tests of Between-Subjects Effects*, nu există un efect principal semnificativ al variabilei *grup* asupra inteligenței emoționale [$F(1, 58) = 1,390, p = 0,243$].

Tests of Between-Subjects Effects

Measure: MEASURE_1

Transformed Variable: Average

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Intercept	12614,260	1	12614,260	22285,983	,000
GRUP	,787	1	,787	1,390	,243
Error	32,829	58	,566		

Vom analiza în continuare efectul de interacțiune prin intermediul contrastelor de interacțiune.

Deoarece numai una dintre VI are mai mult de două nivele [momentul testării] vom putea analiza doar contraste de interacțiune de tipul $\text{moment}_{\text{contrast}} \times \text{grup}$. Vom cerceta dacă amplitudinea efectului în timp al intervenției în cazul elevilor superior dotați (diferența dintre posttest2 și pretest, $M5 - M1$) diferă semnificativ de amplitudinea efectului în timp a intervenției în cazul elevilor mediu dotați (diferența dintre posttest2 și pretest, $M6 - M2$). Coeficienții de contrast vor fi (1 0 -1). Deoarece variabila *moment* este intragrupuri, setul de contraste va fi ortogonal¹, prin urmare vom mai construi un contrast (1 -2 1), care nu ne va interesa însă în analiză. Sintaxa va fi următoarea:

```
MANOVA pretest post_1 post_2 BY grup(1,2)
/WSFACTORS=moment(3)
/PRINT=SIGNIF(AVONLY)
/CONTRAST(moment)=SPECIAL(1 1 1, 1 0 -1, 1 -2 1)
/CONTRAST(grup)=SIMPLE
/WSDESIGN=moment(1)
/DESIGN=grup.
```

Syntax1 - SPSS Syntax Editor

File Edit View Analyze Graphs Utilities Run Window Help



```
MANOVA pretest post_1 post_2 BY grup(1,2)
/WSFACTORS=moment(3)
/PRINT=SIGNIF(AVONLY)
/CONTRAST(moment)=SPECIAL(1 1 1, 1 0 -1, 1 -2 1)
/CONTRAST(grup)=SIMPLE
/WSDESIGN=moment(1)
/DESIGN=grup.
```

1. Am amintit anterior că în cazul unei variabile intragrupuri pot fi specificate și contraste nonortogonale, însă sintaxele sunt mai complicate în această situație.

Am specificat în sintaxă, în cadrul subcomenzii „WSDSIGN”, că vom analiza doar primul contrast, deoarece al doilea nu ne interesa, el fiind construit doar pentru că trebuia să considerăm $(K - 1)$ contraste, iar setul să fie ortogonal. De asemenea, am precizat un contrast (SIMPLE) și pentru variabila intergrupuri *grup*, deși nu ne interesează în analiză.

Rezultatele relevante sunt prezentate mai jos :

Tests involving 'MOMENT(1)' Within-Subject Effect.					
AVERAGED Tests of Significance for MEAS.1 using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	23.09	58	.40		
MOMENT(1)	23.26	1	23.26	58.41	.000
GRUP BY MOMENT(1)	2.40	1	2.40	6.03	.017

Observăm că acest contrast de interacțiune este semnificativ [linia „GRUP BY MOMENT(1)”, prin urmare impactul în timp al intervenției este semnificativ mai puternic în cazul elevilor superior dotați, comparativ cu elevii mediu dotați [$F(1, 58) = 6,03, p = 0,017$].

17.6. Mărima efectelor în ANOVA mixtă

Vom studia mărimea efectelor pentru rezultatele obținute în urma analizei bazei de date *ANOVA_mixtă_1* cu ajutorul formulei:

$$r = \frac{\sqrt{\frac{F(1, df_R)}{F(1, df_R) + df_R}}}{\sqrt{1^2 + df_{eroare}}} = \frac{t}{\sqrt{t^2 + df_{eroare}}}$$

Deoarece calcularea mărimii efectului este utilă pentru efectele specifice, și nu pentru cele generale, vom urmări rezultatele semnificative obținute pentru fiecare comparație-pereche semnificativă (fiecare contrast).

Mărimea efectului principal al variabilei *expectanțe* este :

$$r_{\text{expectanțe}} = \sqrt{\frac{12,757}{12,757 + 87}} = 0,36$$

În cazul efectului principal al variabilei *sarcina* există diferențe semnificative între condițiile *sarcină ușoară/dificilă* și *sarcină medie/dificilă*, așadar, mărimea efectelor va fi :

$$r_{\text{s.usoară-s.dificilă}} = \frac{3,27}{\sqrt{10,69 + 87}} = 0,33$$

$$r_{s.\text{medie}-s.\text{dificilă}} = \frac{3,39}{\sqrt{11,49+87}} = 0,34$$

Analizând acum efectul din interacțiune prin intermediul efectelor simple ale variabilei *expectanțe* se constată că există doar un efect simplu al variabilei *expect* în condiția de *sarcină dificilă*, mărimea acestui efect fiind :

$$r_{\text{expectanțe}-s.\text{dificilă}} = \sqrt{\frac{15,88}{15,88+87}} = 0,39$$

17.7. Prezentarea rezultatelor

Conform rezultatelor obținute, există un efect principal semnificativ al variabilei *expectanțe* asupra variabilei *performanța* și, de asemenea, există un efect principal semnificativ al variabilei *sarcina* asupra variabilei *performanța*. Totodată, există un efect de interacțiune semnificativ statistic al variabilelor *expectanțe* și *sarcina* asupra variabilei *performanța* (tabelul 17.3). Tabelul 17.4 prezintă mediile, abaterile standard și numărul de subiecți în ceea ce privește variabila *performanța* pentru fiecare condiție experimentală, precum și pentru fiecare nivel al variabilei independente *expectanțe*.

Tabelul 17.3. Tabelul ANOVA factorială pentru *performanța* în funcție de *expect* și *sarcina*

Variabile și sursa dispersie	SS	df	MS	F	p
Expectanțe	8,36	1	8,36	12,75	0,001
Eroare (expectanțe)	57,04	87	0,66		
Sarcină	8,34	2	4,17	7,43	0,001
Eroare (sarcină)	48,81	87	0,56		
Expectanțe x Sarcină	4,26	2	2,13	3,24	0,044
Expectanțe					
Sarcină ușoară	0,11	1	0,11	0,17	0,683
Sarcină medie	2,11	1	2,11	3,21	0,077
Sarcină dificilă	10,41	1	10,41	15,88	0,000

Tabel 17.4. Mediile, deviațiile standard și loturile de subiecți pentru *performanța* în funcție de *expectanțe* și *sarcina*

Sarcină	Expectanțe scăzute			Expectanțe ridicate		
	M	SD	n	M	SD	n
ușoară	8,63	0,62	30	8,71	0,82	30
medie	8,50	0,87	30	8,88	0,73	30
ridică	7,81	0,78	30	8,64	0,82	30
Total	8,31	0,84	90	8,74	0,79	90

Analiza efectelor simple ale variabilei *expectanțe* evidențiază existența doar a unui efect simplu semnificativ, în condiția de sarcină dificilă [$F(1, 87) = 15,88, p = 0,000, r = 0,39$]. Așadar, nivelul expectanței are un efect moderat asupra performanței în cazul sarcinilor dificile, un nivel ridicat al expectanțelor conducând la performanțe superioare.

Capitolul 18. ANCOVA (analiza de covarianță)

18.1. Prezentare generală

Analiza de covarianță (ANCOVA) este o extensie a tehnicilor ANOVA care permite controlarea efectului unei/unor variabile cantitative (covariabila) atunci când analizăm efectul unei/unor VI categoriale asupra VD cantitative. Covariabila (numită și variabilă de control) este de regulă o variabilă externă analizei de bază care, dacă nu este controlată, poate conduce la concluzii incorecte privind efectul VI asupra VD. De exemplu, presupunem că studiem efectul motivației (VI nominală, motivație ridicată *versus* scăzută) asupra performanței școlare. Cum performanța este influențată puternic și de coeficientul de inteligență (variabilă cantitativă), concluzia noastră privind efectul motivației asupra performanței ar putea fi eronată în absența controlării efectului inteligenței indivizilor. Prin introducerea QI-ului ca variabilă controlată (covariabilă) putem analiza efectul motivației asupra performanței școlare în condiție de QI constant. Astfel, presupunând că doi sau mai mulți indivizi ar avea același QI am putea studia în ce măsură diferențele dintre aceștia privind performanța școlară sunt influențate de gradul de motivație al acestora.

Preferăm utilizarea ANCOVA (în comparație cu ANOVA) din trei motive :

1. ANCOVA oferă o modalitate de control statistic al egalizării grupelor experimentale relativ la diferențele valori ale covariabilei. De exemplu, într-un design cu două grupe experimentale (una experimentală și alta de control), în care studiem eficiența aplicării unor tehnici de dramă în educație asupra creșterii încrederii interpersonale, vom măsura nivelul de încredere înainte și după intervenția educațională (pretest și posttest). Cum cele două grupe pot diferi încă dinaintea intervenției educaționale în ceea ce privește încrederea interpersonală, prin utilizarea scorurilor la pretest cu rolul de covariabilă ne-am asigurat omogenizarea grupelor experimentale ;
2. ANCOVA reduce varianța eroare (o parte din varianța eroare dată de diferențele interindividuale este explicată), crescând astfel puterea cercetării, respectiv abilitatea de a detecta un efect al VI atunci când acesta există. Cunoscând variabilele externe (variabile care nu fac obiectul principal al analizei) care au efecte importante asupra VD și folosindu-le pe post de covariabile, putem analiza efectul VI asupra VD prin izolarea (controlarea) efectelor covariabilelor. Astfel, în ANCOVA, răspunsurile subiecților la VD sunt ajustate în funcție de valorile covariabilei, ajustare făcută prin calcularea răspunsurilor ipotetice ale subiecților la VD în condițiile în care toți subiecții ar obține același scor la covariabilă. Analizele din ANCOVA iau în calcul tocmai aceste ajustări ale VD.
3. ANCOVA face posibilă analizarea efectelor atât a unor variabile categoriale, cât și cantitative asupra VD, însă doar în condiția în care nu există o interacțiune între VI categoriale și VI cantitative (condiția de absență a interacțiunii este una dintre asumțiile ANCOVA). Dacă interacțiunea este prezentă avem două soluții : fie aplicăm

regresia liniară, fie transformăm variabila cantitativă în variabilă categorială și utilizăm una dintre tehnicile ANOVA.


Condițiile care trebuie respectate în cazul aplicării tehnicii ANCOVA sunt aceleași ca la tehnicile ANOVA (VD cantitativă și normal distribuită și omogenitatea varianțelor sau, după caz, sfericitatea VI), la care se adaugă alte patru :

1. *relația liniară între covariabilă și VD* (condiția este verificată prin coeficienții de corelație Pearson și scatterplot);
2. *omogenitatea pantelor de regresie*: pantele de regresie pentru covariabilă(e) (în relație directă cu VD) trebuie să fie relativ egale pentru fiecare grup experimental; această condiție presupune că *nu există o interacțiune între VI și covariabilă* (dacă F interacțiune este semnificativ, condiția este încălcată);
3. *covariabila trebuie să aibă o fidelitate ridicată* – peste 0,80 (Tabacknick și Fidell, 1996, *apud* Sava, 2004);
4. în cazul existenței mai multor covariabile, corelația dintre acestea trebuie să nu fie ridicată (pentru a se evita multicoliniaritatea, ANCOVA bazându-se pe tehnica regresiei).

18.2. Aplicarea metodei ANCOVA simplă

Presupunem că analizăm efectul implicării în sarcină asupra performanței școlare prin controlarea influenței nivelului de inteligență. Avem două grupe experimentale, una în care este indusă o implicare scăzută subiecților și o alta în care este indusă o implicare ridicată (prin intermediul metodelor de instruire). Nivelul de inteligență este măsurat prin QI iar performanța prin nota școlară.

Deschidem fișierul *ANCOVA*. Calea în SPSS este: *Analyze* → *General Linear Model* → *Univariate*, trecem VD *perf* în câmpul *Dependent Variable*, VI *implic* în câmpul *Fixed Factor(s)* și covariabila *qi* în câmpul *Covariate(s)*.



Activăm butonul *Options*, bifăm opțiunile *Descriptives* și *Homogeneity test*, trecem variabila *implic* în câmpul *Display means for*, apoi clic *Continue*.

Univariate: Options

Estimated Marginal Means
 Factor(s) and Factor Interactions:
 (OVERALL)
 implic

Display Means for:
 implic

☐ Compare main effects
 Confidence interval adjustment:
 LSD (none)

Display
☒ Descriptive statistics
☐ Estimates of effect size
☐ Observed power
☐ Parameter estimates
☐ Contrast coefficient matrix
☒ Homogeneity tests
☐ Spread vs. level plot
☐ Residual plot
☐ Lack of fit
☐ General estimable function

Significance level: .05 Confidence intervals are 95%

Continue Cancel Help

Pentru trasarea graficului activăm butonul *Plot*, trecem variabila *implic* în câmpul *Horizontal Axis*, apoi clic pe butonul *Add*, clic *Continue* și, în final, clic *OK*.

Univariate: Profile Plots

Factors:
 implic

Horizontal Axis:
 Continue

Separate Lines:
 Cancel

Separate Plots:
 Help

Plots: Add Change Remove

implic

18.3. Interpretarea outputului

Rezultatul la testul Levene $F(1, 30) = 3,090$, $p = 0,089$ este nesemnificativ statistic ; prin urmare, condiția de omogenitate a varianțelor este îndeplinită.

Levene's Test of Equality of Error Variances

Dependent Variable: performanta scolara

F	df1	df2	Sig.
3,090	1	30	,089

Tests the null hypothesis that the error variance of the dependent variable is equal across groups.

a. Design: Intercept+QI+IMPLIC

Din tabelul *Tests of Between-Subjects Effects* observăm că efectul VI implicare este semnificativ, $F(1, 29) = 20,787$, $p < 0,001$ și, de asemenea, efectul covariabilei *qi* este semnificativ, $F(1, 29) = 89,747$, $p < 0,001$.


Tests of Between-Subjects Effects

Dependent Variable: performanta scolara

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	12,548 ^a	2	6,274	51,274	,000
Intercept	21,868	1	21,868	178,721	,000
QI	10,981	1	10,981	89,747	,000
IMPLIC	2,543	1	2,543	20,787	,000
Error	3,548	29	,122		
Total	2419,074	32			
Corrected Total	16,096	31			

a. R Squared = ,780 (Adjusted R Squared = ,764)

Graficul ANCOVA este prezentat mai jos.



Cum efectul variabilei *implicare* este semnificativ, conform figurii anterioare rezultă că, în condiția aceluiași nivel de inteligență, subiecții din condiția de implicare ridicată în sarcină au performanțe școlare semnificativ mai mari comparativ cu subiecții din condiția de implicare scăzută.

Mediile din cele două condiții experimentale în absența covariabilei sunt prezentate în tabelul *Descriptive Statistics*, iar mediile ajustate după valorile covariabilei sunt prezentate în tabelul *gradul de implicare* (urmarea selectării opțiunii *Display Means for implic*), ambele fiind prezentate mai jos. Observăm că diferența dintre cele două grupuri în ceea ce privește performanța este mai mare atunci când nivelul de inteligență este controlat (cazul mediilor ajustate, 8,382 și respectiv 8,949), comparativ cu situația în care nivelul de inteligență nu este controlat (8,444 și respectiv 8,886).

Descriptive Statistics

Dependent Variable: performanta scolara

gradul de implicare	Mean	Std. Deviation	N
implicare scazuta	8,4444	,6749	16
implicare ridicata	8,8869	,7163	16
Total	8,6656	,7206	32

gradul de implicare

Dependent Variable: performanta scolara

gradul de implicare	Mean	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
implicare scazuta	8,382 ^a	,088	8,203	8,561
implicare ridicata	8,949 ^a	,088	8,770	9,129

a. Evaluated at covariates appeared in the model: coeficientul de inteligenta = 105,59.

Mărimea efectului (deoarece variabila independentă are doar două nivele) se face conform formulei :

$$r = \sqrt{\frac{F}{F + df_{error}}} = \sqrt{\frac{20,787}{20,787 + 29}} = \sqrt{\frac{20,787}{49,787}} = \sqrt{0,4175} = 0,65$$


Așadar, nivelul de implicare are un efect puternic asupra performanței, în condiția păstrării unui nivel de inteligență constant.

Vom verifica în continuare dacă și celelalte condiții de aplicare ale tehnicii ANCOVA au fost îndeplinite. Pentru verificarea relației liniare dintre QI și performanță calculăm coeficientul de corelație Pearson (*Analyze* → *Correlate* → *Bivariate*) și inspectăm graficul Scatterplot (*Graph* → *Scatter*). Rezultatele obținute sunt prezentate în continuare.

Correlations

		performanta scolara	coeficientul de inteligenta
performanta scolara	Pearson Correlation	1,000	,788**
	Sig. (2-tailed)	.	,000
	N	32	32
coeficientul de inteligenta	Pearson Correlation	,788**	1,000
	Sig. (2-tailed)	,000	.
	N	32	32

** . Correlation is significant at the 0.01 level (2-tailed).



Din tabelul *Correlations* observăm că există o corelație puternică între *QI* și *performanță*, $r(30) = 0,788$, și, de asemenea, din grafic că relația dintre cele două variabile este liniară.


18.4. Verificarea omogenității pantelor de regresie

Verificarea condiției de omogenitate a pantelor de regresie se poate face prin raportare atât la un criteriu grafic, cât și la unul statistic.


18.4.1. Criteriul grafic de verificare a omogenității pantelor de regresie

Criteriul grafic presupune inspectarea grafică a paralelismului pantelor de regresie. Călea în SPSS este: *Graph* → *Scatter* → *Simple* → *Define*; trecem VD *performanță* în


câmpul *Y Axis*, covariabila *qi* în câmpul *X Axis* și *VI gradul de implicare* în câmpul *Set Markers by*, apoi clic *OK*.




Facem dublu-clic pe grafic, iar în fereastra *Chart editor* activăm meniul *Chart* → *Options*.



În câmpul *Fit Line* bifăm opțiunea *Subgroups*, apoi clic *OK* și închidem fereastra *Chart editor*.



Din graficul prezentat mai jos, observăm că pantele de regresie, deși nu sunt strict paralele, nici nu se intersectează, așadar am putea considera îndeplinită condiția. Pentru siguranță vom apela și la criteriul statistic.



18.4.2. Criteriul statistic de verificare a omogenității pantelor de regresie

Verificarea statistică a omogenității pantelor de regresie (a absenței interacțiunii dintre covariabilă și VI) presupune calcularea unui test F de interacțiune între covariabilă și VI. Există trei tehnici statistice disponibile:

1. tehnica elaborării unui nou model ANCOVA;
2. tehnica sintaxelor;
3. tehnica regresiei ierarhice (această variantă fiind mai complicată, nu o vom detalia aici).

18.4.2.1. Verificarea omogenității pantelor de regresie prin tehnica elaborării unui nou model ANCOVA

În meniul *Analyze* → *General Linear Model* → *Univariate*, trecem VD *perf* în câmpul *Dependent Variable*, VI *implicare* în câmpul *Fixed Factor(s)* și covariabila *qi* în câmpul *Covariate*, activăm butonul *Model*, bifăm opțiunea *Custom* și trecem *qi* și *performanță* în câmpul din dreapta (prin dublu-clic), apoi în câmpul din stânga bifăm *qi*, ținem apăsată tasta *CTRL* și bifăm *performanță* (în acest moment ambele variabile sunt selectate), apoi clic pe butonul *Build Term* și în acest mod am trecut și interacțiunea în modelul nou construit (câmpul din dreapta); clic *Continue* și clic *OK*.

Univariate: Model

Specify Model

☐ Full factorial ☒ Custom

Factors & Covariates:

implic(F)
qi(C)

Build Term(s)

Interaction

Model:

implic
qi
implic:qi

Sum of squares: Type III ☒ Include intercept in model

Continue Cancel Help

În tabelul *Tests of Between-Subjects Effects 1* prezentat mai jos observăm că interacțiunea dintre *implicare* și *qi* este nesemnificativă, $F(1, 28) = 3,219$, $p = 0,084$, așadar condiția absenței interacțiunii și implicit a omogenității pantelor de regresie este îndeplinită.

Tests of Between-Subjects Effects

Dependent Variable: performanta scolara


Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	12,914 ^a	3	4,305	37,871	,000
Intercept	20,828	1	20,828	183,245	,000
IMPLIC	,115	1	,115	1,011	,323
QI	11,333	1	11,333	99,704	,000
IMPLIC * QI	,366	1	,366	3,219	,084
Error	3,183	28	,114		
Total	2419,074	32			
Corrected Total	16,096	31			

a. R Squared = ,802 (Adjusted R Squared = ,781)

18.4.2.2. Verificarea omogenității pantelor de regresie prin tehnica sintaxelor

Sintaxa pentru verificarea omogenității pantelor de regresie este :

```
MANOVA perf BY implic(1,2) WITH qi
/ANALYSIS=perf
/DESIGN=implic, qi, implic BY qi.
```

Rezultatele relevante sunt prezentate mai jos și observăm că sunt similare celor din tabelul *Tests of Between-Subjects Effects* anterior.

Tests of Significance for PERF using UNIQUE sums of squares					
Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	3.18	28	.11		
IMPLIC	.11	1	.11	1.01	.323
QI	11.33	1	11.33	99.70	.000
IMPLIC BY QI	.37	1	.37	3.22	.084
(Model)	12.91	3	4.30	37.87	.000
(Total)	16.10	31	.52		
R-Squared =	.802				
Adjusted R-Squared =	.781				

Observație. ANCOVA este o extensie a tehnicilor ANOVA ; aşadar vom putea vorbi despre ANCOVA simplă, ANCOVA factorială, ANCOVA simplă cu măsurători repetate, ANCOVA factorială cu măsurători repetate, ANCOVA mixtă. De asemenea, numărul de covariabile este decis de cercetător în funcție de importanța lor, avându-se în vedere totuși îndeplinirea condițiilor de aplicare ale ANCOVA.

18.5. Prezentarea rezultatelor

Pentru a verifica efectul nivelului de implicare în sarcină (*ridicat* versus *scăzut*) asupra performanței în condiția controlării efectului nivelului de inteligență am aplicat analiza de covarianță ANCOVA. Rezultatele arată că după controlarea nivelului de inteligență, subiecții din condiția de implicare ridicată obțin performanțe semnificativ mai mari comparativ cu cei din condiția de implicare scăzută [$F(1, 29) = 89,747, p < 0,001$] (tabelul 18.2). Mărimea efectului gradului de implicare asupra performanței, în condiția controlării nivelului de inteligență, este $r = 0,65$. Tabelul 18.1 prezintă mediile și deviațiile standard pentru subiecții din cele două condiții ale variabilei *implicare*, înainte și după controlarea nivelului de inteligență.

Tabelul 18.1. Mediile și indicatorii varianței, ajustate și neajustate, pentru *performanță*, în cazul fiecărui nivel al variabilei *implicare*, controlând nivelul QI

	N	Neajustate		Ajustate	
		M	SD	M	SE
Implicare scăzută	16	8,44	0,67	8,38	0,09
Implicare ridicată	16	8,88	0,71	8,94	0,09

Tabelul 18.2. Analiza de covarianță pentru efectul variabilei *implicare* asupra variabilei *performanță*, controlând nivelul de inteligență

Sursa varianței	SS	df	MS	F
Nivelul intelectual	10,981	1	10,981	89,747*
Nivelul de implicare	2,543	1	2,543	20,787*
Reziduală (eroare)	3,548	29		
Total	16,096	31		

* $p < 0,001$

Exerciții SPSS

ANOVA

1. Urmărim să dezvoltăm nivelul empatiei elevilor prin două metode diferite (metoda 1 și metoda 2). Pentru că vom lucra cu două clase de liceu nu vom putea face omogenizarea grupelor înainte de intervenție. Vom controla totuși nivelul inițial al empatiei, măsurând empatia elevilor înainte de intervenție. Apoi, la una dintre clase vom aplica metoda 1, iar la cealaltă clasă metoda 2. Aplicarea celor două metode se va desfășura pe parcursul a două luni. În final, vom măsura din nou nivelul empatiei elevilor. Aflați care dintre cele două metode a fost mai eficientă în dezvoltarea empatiei elevilor, controlând nivelul empatic inițial al acestora. Baza de date este *Dezvoltare_empatie*.
2. Vom analiza în ce măsură două surse de influență au efect asupra schimbării atitudinii subiecților imediat după expunere și la două luni după expunere. Vom evalua atitudinea inițială a tuturor subiecților (faza pretest), apoi aceștia vor fi împărțiți în două grupe relativ omogene. Ulterior, grupul 1 va fi supus unei influențe prin joc de rol, iar grupul 2 va fi supus unei influențe prin sursă de tip expert. Vom măsura atitudinea celor două grupe imediat după expunerea la influență (faza posttest 1) și apoi la două luni după expunere (faza posttest 2). Designul este de tipul 2 (surse de influență: *joc de rol* versus *sursă-expert*) $\times$ 3 (momentul măsurării: *pretest*, *posttest 1* și *posttest 2*) și este ilustrat în tabelul 18.3 de mai jos. Baza de date este *Sursa_influenta*.

Tabel 18.3. *Design 2 × 3*

Subiecții	Influență prin joc de rol			Subiecții
	pretest	posttest 1	posttest 2	
1				31
2				32
3				33
...				...
30				60

3. Să analizăm influența tipului de motivare asupra atractivității sarcinii și a intențiilor viitoare de participare în sarcini similare. Avem trei grupe de subiecți care participă într-o sarcină de grup. După terminarea sarcinii (indiferent de rezultatele obținute) grupul 1 este lădat pentru rezultatele bune obținute, grupul 2 este muștrat pentru rezultatele slabe obținute, iar grupul 3 (grup de control) nu primește nici un tip de feedback. Ulterior, fiecărui participant din cele trei grupe i se administrează un chestionar care măsoară: a) atractivitatea sarcinii desfășurate și b) intențiile viitoare de participare în sarcini similare. Verificați dacă există diferențe semnificative în funcție de cele trei strategii diferite de motivare în ceea ce privește *atractivitatea sarcinii* și *intențiile viitoare de participare* în sarcini similare. Baza de date este *Tehnici_motivare*.

Capitolul 19. Regresia liniară simplă

Metoda regresiei liniare este utilă în verificarea unor modele predictive sau explicative în cercetarea psihopedagogică. În primul caz, vom vorbi despre metoda regresiei liniare aplicată în scop predictiv, în al doilea caz vom vorbi despre metoda regresiei liniare utilizată în scop explicativ.

Variabila dependentă trebuie să fie întotdeauna cantitativă, în vreme ce variabila sau variabilele independente pot fi cantitative sau categoriale. În cazul unei regresii cu una sau mai multe VI categoriale, variabilele categoriale vor fi transformate în variabile dummy (variabilele dummy pot lua numai două valori, 1 și 0), iar în acest caz avem o regresie liniară cu variabile dummy.

Există două tipuri de regresie liniară, în funcție de numărul de VI:


1. regresia liniară simplă sau bivariată (cu o singură VI);
2. regresia liniară multiplă (cu două sau mai multe VI).

19.1. Prezentare generală


Scop. Metoda regresiei liniare simple este o extensie a corelației liniare Pearson, fiind utilă în descrierea relației dintre o VI și o VD în termenii unităților de măsură ale variabilelor în cauză. Vom putea prezice – prin intermediul unei ecuații de regresie – scorul unei persoane la VD, cunoscând scorul obținut de aceasta la VI. Aplicarea regresiei liniare simple în scop explicativ urmărește aflarea procentului din varianța VD explicat de varianța VI, fiindu-ne utilă în acest caz valoarea lui R^2 .

Ecuația de regresie este dată de formula $Y = a + b \cdot X$, unde Y reprezintă VD, X reprezintă VI, a reprezintă interceptul (sau punctul de intersecție dintre dreapta de regresie cu axa OY), iar b este panta de regresie (și arată cu cât crește sau descrește Y atunci când X se modifică cu o unitate). În cazul regresiei liniare simple, ecuația de regresie reprezintă de fapt o dreaptă de regresie (pentru o regresie liniară multiplă cu două VI, vom vorbi despre un plan de regresie etc.).

Atunci când corelația dintre X și Y este negativă, panta de regresie b ia o valoare negativă [dreapta de regresie este descrescătoare, cazul a] din figura următoare, iar în cazul unei corelații pozitive între X și Y panta de regresie b ia o valoare pozitivă [dreapta de regresie este crescătoare, cazul b].



(a)



(b)

Condițiile aplicării regresiei liniare simple :


1. VI și VD sunt cantitative și normal distribuite ;
2. relația dintre VI și VD este liniară ;
3. erorile sunt normal distribuite ;
4. evitarea cazurilor influente și a cazurilor extreme.

În analiza de regresie, VI numesc *predictor(i)*, iar VD se numește *criteriu*.


Exemple. 1) Analizăm validitatea unui test de inteligență nou construit (test QI1) prin corelarea cu altul existent (test QI2). Dacă rezultatele analizei de regresie sunt semnificative, vom putea prezice scorul unei persoane la testul QI2 pe baza scorului obținut de acea persoană la testul QI1 ; 2) Analizăm în ce măsură aptitudinile de leadership sunt explicate de inteligența emoțională a individului.

19.2. Aplicarea regresiei liniare simple


Să analizăm dacă inteligența muzicală a indivizilor influențează rezultatele acestora la examenul de admitere la Conservator. Pentru aceasta, aplicăm candidaților un test care măsoară inteligența muzicală și înregistrăm de asemenea rezultatele acestora la examenul de admitere. Deschidem fișierul *Regresie_simpla*. Calea în SPSS este: *Analyze* → *Regression* → *Linear*.




Trecem variabila *rezultate examen* (VD, variabila care trebuie prezisă) în câmpul din dreapta *Dependent*, iar variabila *inteligenta muzicala* (VI) în câmpul *Independent*.



Pentru verificarea condițiilor 3 și 4 activăm butonul *Plots*, iar aici trecem *Zrezid* pe axa *Y* și *Zpred* pe axa *X*, bifăm *Histogram* și *Normal probability plot* (pentru a verifica normalitatea distribuției reziduurilor) și clic *Continue*.



Activăm apoi butonul *Save*, iar în câmpul *Residual* bifăm *Standardized* și *Studentized* (pentru identificarea unor posibile cazuri extreme), apoi în câmpul *Distances* bifăm *Cook's* (pentru identificarea unor posibile cazuri influente), clic *Continue* și *OK*.



19.3. Interpretarea outputului

Primul tabel din output ne interesează mai puțin. Următorul tabel – *Model Summary* – este important, deoarece ne oferă primele informații despre eficiența modelului de regresie aplicat.

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,808 ^a	,654	,651	,9766

a. Predictors: (Constant), inteligența muzicală

b. Dependent Variable: rezultate examen

În coloana a doua este prezentat *coeficientul de corelație Pearson* dintre VD și VI, notat prin R (este cunoscut și ca R multiplu sau coeficient de corelație multiplă, în cazul în care modelul conține mai mult de o variabilă independentă). Cum $R = 0,808$, rezultă că între cele două variabile există o corelație puternică. Evident, predicția este cu atât mai bună cu cât R este mai ridicat. Coeficientul R ne spune cât de bine se grupează datele noastre în jurul liniei de regresie. Dacă datele sunt îndepărtate față de linia de regresie, atunci predicția nu este prea bună, iar valoarea lui R va fi scăzută.

Coloana a treia conține *coeficientul de determinare* $R^2 = 0,654$, ceea ce înseamnă că 65,4% din varianța variabilei dependente poate fi explicată de varianța variabilei independente. Putem spune că 65% dintre rezultatele candidaților la examen pot fi explicate de inteligența muzicală a acestora sau că inteligența muzicală a indivizilor influențează în proporție de 65% rezultatele acestora la examen.

În coloana a patra este prezentat *coeficientul R^2 ajustat*. Coeficientul R^2 este în general mai mare (comparativ cu $R^2_{ajustat}$), fiind influențat de numărul de VI supuse analizei (în regresia multiplă) și volumul eșantionului și are în vedere cea mai bună linie de regresie obținută pe baza rezultatelor din eșantion. Cum pe noi ne interesează generalizarea rezultatelor asupra populației, $R^2_{ajustat}$ este un estimator mult mai bun. În cazul nostru, $R^2_{ajustat} = 0,651$, diferența fiind minimă comparativ cu R^2 . Vom spune că, în general, inteligența muzicală a indivizilor influențează în proporție de 65,1% rezultatele acestora la examen.

În sfârșit, în coloana a cincea este prezentată *eroarea standard a estimării*. Informațiile obținute până acum nu sunt absolut independente de anumite erori ce pot apărea. Dacă realizăm același studiu pe alte eșantioane, rezultatele ar fi în mod evident puțin diferite. Deviația standard a acestor rezultate este numită *eroarea standard* și indică acuratețea estimării pe care o facem pe baza rezultatelor obținute pe eșantion. Astfel, eroarea standard (în cazul nostru 0,976) este o estimare a varianței lui Y (VD, rezultatele la examen) pentru fiecare valoare a lui X (VI, inteligența muzicală). Eroarea standard a estimării este rădăcina pătrată (radical) din valoarea lui *Residual mean square* din tabelul ANOVA următor, iar unitățile sale de măsură corespund variabilei dependente.

În următorul tabel, ANOVA, testul F verifică dacă linia de regresie este semnificativ diferită de 0, adică dacă predicția pe care o facem este mai bună decât cea bazată pe șansă, întâmplare. Dacă panta $b = 0$, atunci linia de regresie este orizontală. Cum

$F(1, 116) = 218,930$ este semnificativ ($p < 0,001$) rezultă că este foarte puțin probabil ca rezultatele noastre să apară dintr-o eroare de eșantionare. Testul F este folosit pentru a testa ipoteza nulă conform căreia panta b este 0 (sau pentru regresia multiplă $b_1, b_2, \dots, b_n = 0$). Dacă VI este un bun predictor al VD, atunci valoarea lui F este ridicată și semnificativă, ceea ce înseamnă că VI ne ajută în explicarea varianței VD.

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	208,786	1	208,786	218,930	,000 ^a
	Residual	110,625	116	,954		
	Total	319,411	117			

a. Predictors: (Constant), inteligenta muzicala

b. Dependent Variable: rezultate examen

În tabelul *Coefficients* sunt prezentați coeficienții de regresie nestandardizați (B) și standardizați (beta) precum și rezultatele testelor t pentru fiecare dintre acești coeficienți. Pentru regresia liniară simplă, beta (coeficientul standardizat $\beta = 0,808$) este coeficientul de corelație dintre VI și VD. Coeficientul nestandardizat pentru variabila inteligență muzicală este $b = 0,216$ și reprezintă panta dreptei de regresie. Coeficientul nestandardizat pentru constantă este $a = 1,322$ și reprezintă interceptul.

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	1,322	,360		3,670	,000
	inteligenta muzicala	,216	,015	,808	14,796	,000

a. Dependent Variable: rezultate examen

Putem scrie acum ecuația de regresie $Y = a + b \cdot X = 1,322 + 0,216 \cdot X$ pentru a prezice rezultatele la examen pe baza scorului la test. Astfel, estimăm că un individ care obține un scor de 30 de puncte la testul de inteligență muzicală va lua nota 7,80 la examen ($1,322 + 0,216 \cdot 30 = 1,32 + 6,48 = 7,80$).

Valoarea pantei b transformată într-un scor standardizat beta arată că atunci când inteligența muzicală crește cu o deviație standard, nota la examen crește cu 0,808 deviații standard. Valorile semnificative la testele t indică semnificația statistică a variabilei predictor. Valorile la testul t sunt obținute prin împărțirea fiecărui coeficient nestandardizat (B) la eroarea sa standard. Testul t pentru b testează semnificația pantei, care este echivalent cu testarea semnificației corelației între VI și VD. În regresia simplă, acest t ridicat la pătrat este F din tabelul ANOVA. Testul t pentru constantă studiază semnificația diferenței constante față de 0 și rareori atrage atenția cercetătorilor.

Indicatorii mărimii efectului în cazul regresiei liniare simple sunt R și R^2 ajustat; în cazul nostru, $R = 0,81$ și, conform lui Cohen (1988), vorbim despre un efect foarte puternic al inteligenței muzicale asupra rezultatelor la examen.

Să analizăm acum în ce măsură condițiile 3 și 4 sunt îndeplinite. Dacă vom studia graficele, vom observa că erorile sunt normal distribuite. Pentru verificarea condiției 4, vom urmări rezultatele din tabelul *Residuals Statistics*.

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	3,2677	8,8886	6,4831	1,3358	118
Std. Predicted Value	-2,407	1,801	,000	1,000	118
Standard Error of Predicted Value	8,992E-02	,2352	,1229	3,268E-02	118
Adjusted Predicted Value	3,2534	8,8907	6,4834	1,3358	118
Residual	-2,8391	2,8723	-3,33E-15	,9724	118
Std. Residual	-2,907	2,941	,000	,996	118
Stud. Residual	-2,954	2,954	,000	1,004	118
Deleted Residual	-2,9312	2,8974	-3,31E-04	,9877	118
Stud. Deleted Residual	-3,059	3,059	-,002	1,015	118
Mahal. Distance	,000	5,794	,992	1,125	118
Cook's Distance	,000	,142	,008	,015	118
Centered Leverage Value	,000	,050	,008	,010	118

a. Dependent Variable: rezultate examen

Dacă mai mult de 1 % dintre valorile *Std. Residual* și *Stud. Residual* se află în afara intervalului $[-3, +3]$, ecuația de regresie nu este stabilă (Field, 2000). Cum valorile minime și maxime din tabel corespundătoare celor doi indicatori nu depășesc acest interval vom considera că nu există cazuri extreme. Vom urmări și valoarea maximă a distanței lui *Cook*; dacă aceasta este mai mare decât 1, atunci există cazuri influente (Field, 2000). Nu este cazul aici, valoarea maximă fiind 0,142; prin urmare nu există cazuri influente. Vom reveni asupra verificării acestor două condiții în cazul regresiei multiple.

19.4. Realizarea graficelor pentru regresia liniară simplă

Pentru a obține o ilustrare grafică, calea în SPSS este: *Graph* → *Scatterplot* → *Simple* → *Define*, pe axa Y trecem VD, *rezultatul la examen*, iar pe axa X trecem VI, *inteligența muzicală*, și clic *OK*.



Regresie_simpla - SPSS Data Editor

File Edit View Data Transform Analyze **Graphs** Utilities Windows

1: intelmuz 33



	intelmuz	examen	zre
1	33	10,00	1,5
2	32	9,17	9
3	25	7,67	9
4	28	8,17	8
5	28	8,00	8
6	31	8,00	-0
7	35	10,00	1,1
8	27	7,00	-1
9	32	7,33	-9

Gallery
Interactive
Bar...
Line...
Area...
Pie...
High-Low...
Pareto...
Control...
Boxplot...
Error Bar...
Scatter...




Obținem astfel norul de puncte reprezentând relația dintre cele două variabile. Pentru obținerea dreptei de regresie, facem dublu-clic pe grafic și apoi: **Chart** → **Options** → **Fit**

Line → Total → OK și închidem noua fereastră apărută. Graficul obținut este prezentat mai jos.



Cu cât sunt mai apropiate punctele de dreapta de regresie, cu atât mai mare este coeficientul de corelație, iar rezultatele la analiza de regresie sunt mai bune.



19.5. Prezentarea rezultatelor

Pentru a verifica gradul de predicție al rezultatelor la un test de inteligență muzicală asupra rezultatelor la examenul de admitere la Conservator am aplicat metoda regresiei liniare simple. Rezultatele au fost semnificative statistic, $F(1, 116) = 219,930$, $p < 0,001$. Ecuația de regresie obținută este : $\text{rezultate examen} = 1,322 + 0,216 \cdot (\text{inteligență muzicală})$. Valoarea lui R^2 ajustat este 0,651, ceea ce înseamnă că 65,1% din varianța rezultatelor la examen poate fi explicată de inteligența muzicală a subiecților. Conform lui Cohen (1988), acesta este un efect puternic.

Tabel 19.1. Rezultatele analizei de regresie vizând estimarea rezultatelor la examen pe baza scorurilor la testul de inteligență muzicală

	R	R^2	β	b	SE b
Inteligența muzicală	0,808	0,654	0,808*	0,216*	0,015

Notă. Variabila dependentă : rezultate examen ; * $p < 0,001$

Capitolul 20. Regresia liniară multiplă

20.1. Prezentare generală

Atunci când studiem efectul a două sau mai multe VI asupra unei VD vorbim despre regresie liniară multiplă.

Scop. Regresia multiplă poate servi unor scopuri diferite, precum : 1) predicția unei VD pe baza mai multor VI ; 2) explicarea VD pe baza unor VI ; 3) identificarea unui set de VI (dintre mai multe VI) care este mai eficient în estimarea VD ; 4) oferirea unui răspuns la întrebarea : includerea unei anumite VI în model aduce un plus explicativ pentru VI ? 5) stabilirea importanței unei VI incluse în analiză, prin comparație cu alte VI incluse în model.

Similar regresiei simple, și în regresia multiplă predicția unei VD pe baza mai multor VI se face cu ajutorul unei ecuații de regresie. Fie Y variabila dependentă, $X_1, X_2, \dots, X_n$ variabilele independente, $b_1, b_2, \dots, b_n$ coeficienții de regresie corespunzători VI și a interceptul (constanta). Ecuația de regresie va fi :

$$Y = a + b_1 \cdot X_1 + b_2 \cdot X_2 + \dots + b_n \cdot X_n \quad (20.1)$$

Condițiile necesare (asumpțiile) pentru aplicarea regresiei liniare multiple sunt :

1. VD să fie cantitativă, iar VI să fie cantitative sau dihotomice (variabile dummy - codificate cu 0 și 1) ; variabilele cantitative trebuie să fie normal distribuite ;
2. relația dintre fiecare VI și VD să fie liniară ; verificarea acestei condiții se face prin intermediul vizualizării grafice (scatterplot - matrix) ;
3. erorile (reziduurile) sunt normal distribuite ;
4. evitarea multicolarității : a) să nu existe corelații ridicate între oricare două VI sau b) o VI să nu fie o combinație liniară de alte VI ;
5. evitarea cazurilor extreme și a cazurilor influente ;
6. *homoscedasticitatea* : reziduurile vor avea aceeași varianță pentru fiecare nivel al predictorilor ; când varianța este foarte inegală vorbim despre *heteroscedasticitate*.

Exemple. 1) Analizăm eficiența unui model explicativ în care VI sunt inteligență socială și inteligență emoțională, iar VD este aptitudinea de leadership. 2) Analizăm care dintre următoarele două VI - abilități verbale și abilități logico-matematice - influențează într-o măsură mai mare performanța școlară.

Metodele de analiză în regresia liniară multiplă sunt :

1. *Metoda simultană* (enter) - folosită atunci când există un număr mic de VI, iar cercetătorul nu are motive a priori (pe baza literaturii de specialitate studiate) să considere că anumite VI contribuie la o mai bună explicare (sau predicție) a VD. Selectarea VI relevante se va face în urma inspectării coeficienților beta și a repetării metodei de regresie.
2. *Metoda ierarhică* - folosită atunci când cercetătorul știe ordinea în care vrea să introducă VI în model și vrea să afle dacă introducerea unor noi VI în model aduce


- un plus de claritate sau predicție în ceea ce privește VD. Menținem ca metodă „enter” și după introducerea primului set de VI apăsăm butonul „next”, apoi reintroducem toate variabilele din primul set la care mai adăugăm alte VI pe care le avem în vedere pentru al doilea set (se poate continua și cu al treilea set etc.).
3. *Metoda celui mai bun set posibil* (stepwise) constă în introducerea tuturor VI care ne interesează și compararea tuturor modelelor posibile. SPSS va selecta modelul cu coeficientul de determinare R^2 ajustat cel mai mare, renunțându-se la VI care au coeficienți de corelație parțială scăzuți.
 4. *Metoda pașilor* – înainte (forward) sau înapoi (backward). În varianta „înapoi” (backward), sunt luate în calcul toate VI introduse și eliminate rând pe rând cele care nu aduc un plus în cadrul coeficientului de determinare ajustat și au corelații parțiale scăzute cu VD. Este astfel selectat pe baze pur statistice modelul de regresie care conține acele VI ce explică statistic cel mai mult VD. În varianta „înainte” (forward), sunt introduse rând pe rând acele VI care contribuie cel mai mult la coeficientul de determinare al modelului de regresie (în funcție de mărimea corelației parțiale). Se alege astfel, tot pe baze pur statistice, modelul cel mai bun.
 5. *Metoda eliminării* (remove) elimină din analiză variabilele în bloc, într-un singur pas. Majoritatea cercetătorilor nu o iau în calcul.


Dintre cele cinci metode, primele două sunt cel mai frecvent folosite, deoarece combină atât criteriile teoretice, cât și statistice în alegerea modelului potrivit de regresie. Metodele 3 și 4 sunt criticate, deoarece iau în calcul doar criteriile statistice în stabilirea modelului potrivit de regresie, existând riscul includerii în model a unei/unor VI irelevante teoretic și excluderea unor VI importante.

20.2. Aplicarea regresiei liniare multiple prin metoda ierarhică


Verificăm dacă și în ce măsură o serie de variabile precum dominanța, atitudinea proactivă, inteligența emoțională și autoeficiența explică aptitudinile de leadership. Vom aplica regresia liniară multiplă prin metoda ierarhică. Deschidem fișierul *Regresie multiplă*.

Verificăm mai întâi dacă există o relație liniară între VI și VD (condiția 2). Vom inspecta graficele din figura de mai jos și coeficienții de corelație Pearson între VI și VD din tabelul *Correlations*. Verificarea relației liniare dintre VD și VI prin metoda grafică se face pe calea: *Graphs* → *Scatterplots* → *Matrix*, clic *Define*, trecem VD și VI în câmpul *Matrix Variables* și clic OK.





Din graficul de mai jos se observă că relația dintre VD și fiecare VI este liniară, iar inspectând coeficienții de corelație din tabelul *Correlations*, constatăm că între fiecare VI și VD corelațiile sunt de nivel mediu și ridicat. Așadar, condiția 2 este îndeplinită.



Dacă există corelații ridicate între VI (mai mari de 0,50 sau 0,60), atunci putem vorbi despre o problemă de multicolinearitate (Leech, Barrett și Morgan, 2005). Observăm că o asemenea corelație apare între variabilele *atitudine proactiva* și *autoeficienta*. Dacă vom realiza un model de regresie care să conțină aceste variabile ca VI, atunci rezultatele ar putea fi distorsionate din cauza problemei de multicolinearitate. Am putea decide eliminarea uneia dintre aceste variabile (probabil VI *autoeficienta*, deoarece corelează mai slab cu leadershipul) sau combinarea lor într-un indice. Le vom păstra momentan în modelul de regresie pe ambele pentru a ilustra cum afectează multicolinearitatea valorile toleranței și a coeficienților beta.

Correlations

		aptitudini de leadership	inteligenta emotionala	dominanta	atitudine proactiva	autoeficienta
aptitudini de leadership	Pearson Correlation	1,000	,571**	,473**	,494**	,336**
	Sig. (2-tailed)		,000	,000	,000	,001
	N	100	100	100	100	100
inteligenta emotionala	Pearson Correlation	,571**	1,000	,253*	,386**	,217*
	Sig. (2-tailed)	,000		,011	,000	,030
	N	100	100	100	100	100
dominanta	Pearson Correlation	,473**	,253*	1,000	,341**	,219*
	Sig. (2-tailed)	,000	,011		,001	,029
	N	100	100	100	100	100
atitudine proactiva	Pearson Correlation	,494**	,386**	,341**	1,000	,560**
	Sig. (2-tailed)	,000	,000	,001		,000
	N	100	100	100	100	100
autoeficienta	Pearson Correlation	,336**	,217*	,219*	,560**	1,000
	Sig. (2-tailed)	,001	,030	,029	,000	
	N	100	100	100	100	100

** . Correlation is significant at the 0.01 level (2-tailed).

* . Correlation is significant at the 0.05 level (2-tailed).

Să aplicăm acum metoda regresiei ierarhice. Conform literaturii de specialitate, știm că aptitudinile de leadership sunt influențate de variabilele *inteligenta emotionala* și *dominanta*, acestea fiind conținute în primul model de regresie. Următorul model va conține variabilele din primul bloc la care adăugăm *atitudinea proactiva*. Al treilea model conține variabilele din modelul 2 la care adăugăm variabila *autoeficienta*. Călea în SPSS este: *Analyze* → *Regression* → *Linear*.

Mai întâi, trecem variabila *aptitudini de leadership* în câmpul *Dependent*, iar variabilele *inteligenta emotionala* și *dominanta* în câmpul *Independent*. În câmpul *Method*, ne asigurăm că este selectată metoda *Enter*. Apăsăm butonul *Next* și astfel am construit primul model de regresie: Pentru construirea modelului 2, trecem variabilele *inteligenta emotionala*, *dominanta* și *atitudine proactiva* în câmpul *Independent* și apăsăm din nou butonul *Next*. La fel, pentru construirea modelului 3 selectăm alături de variabilele anterioare și variabila *autoeficienta* și le trecem în câmpul *Independent*.

Linear Regression

Dependent:

Independent(s):

Method:

Selection Variable:

Case Labels:

WLS >> Statistics... Plots... Save... Options...

OK Paste Reset Cancel Help

Activăm butonul *Statistics*, iar aici, în câmpul *Regression Coefficients*, bifăm următoarele opțiuni:

- *Estimates* – SPSS va calcula, în cazul fiecărei VI introduse în model, coeficienții standardizați și cei nestandardizați de regresie, eroarea standard a acestora, precum și testele *t* pentru testarea ipotezei nule conform căreia acești coeficienți de regresie sunt zero;
- *Model fit* – pentru a fi calculați coeficientul de corelație multiplă R , coeficientul de determinare R^2 și coeficientul de determinare ajustat R^2_{ajustat} ;
- *R squared change*: fiind în cazul regresiei ierarhice, ne interesează să știm cât de mult își schimbă valoarea coeficientul de determinare R^2 ajustat de la un model la altul și dacă această schimbare este semnificativă statistic; acest lucru ne permite să estimăm dacă introducerea unei noi VI sau a unui bloc de VI îmbunătățește puterea explicativă a modelului;
- *Descriptives* – afișează mediile și deviațiile standard pentru VI și VD;
- *Part and partial correlation* – vor fi calculați coeficienții de corelație parțiali între VI și cei parțiali între fiecare VI și VD, lucru util pentru verificarea multicolarității și eventual excluderea din model a unei VI care are un coeficient de corelație parțială scăzut cu VD;
- *Collinearity diagnostics* – efectuarea unor teste de coliniaritate, pentru a evita multicolaritatea (condiția 4) și clic *Continue*.

Linear Regression: Statistics

Regression Coefficients

☒ Estimates

☐ Confidence intervals

☐ Covariance matrix

☒ Model fit

☒ R squared change

☒ Descriptives

☒ Part and partial correlations

☒ Collinearity diagnostics

Residuals

☐ Durbin-Watson

☐ Casewise diagnostics

☒ Outliers outside 3 standard deviations

☐ All cases

Continue

Cancel

Help

Activăm butonul *Plots*, iar aici trecem *ZRESID* pe axa *Y* și *ZPRED* pe axa *X* (pentru a verifica dacă predictorii și reziduurile sunt necorelate). Bifăm apoi *Histogram* (pentru a verifica dacă reziduurile standardizate sunt distribuite normal – așa cum ar trebui pentru ca modelul nostru să fie valid – condiția 3) și *Normal probability plot* (pentru a verifica normalitatea distribuției reziduurilor prin comparație cu abaterile de la curba normală – condiția 3) și clic *Continue*.

Linear Regression: Plots

DEPENDNT

*ZPRED

*ZRESID

*DRESID

*ADJPRED

*SRESID

*SDRESID

Previous Scatter 1 of 1 Next

Y: *ZRESID

X: ZPRED

Standardized Residual Plots

☒ Histogram

☒ Normal probability plot

☒ Produce all partial plots

Continue

Cancel

Help

Activăm butonul *Save*, în câmpul *Residuals* bifăm *Standardized* și *Studentized*, în câmpul *Distances* bifăm *Cook's*, click *Continue* și *OK*.

Linear Regression: Save

Predicted Values ☐ Unstandardized ☐ Standardized ☐ Adjusted ☐ S.E. of mean predictions	Residuals ☐ Unstandardized ☒ Standardized ☒ Studentized ☐ Deleted ☐ Studentized deleted	Continue Cancel Help
Distances ☐ Mahalanobis ☒ Cook's ☐ Leverage values	Influence Statistics ☐ DfBeta(s) ☐ Standardized DfBeta(s) ☐ DfFit ☐ Standardized DfFit ☐ Covariance ratio	
Prediction Intervals ☐ Mean ☐ Individual Confidence Interval: 95 %		
Save to New File ☐ Coefficient statistics File...		
Export model information to XML file Browse		

20.3. Interpretarea outputului

În continuare vom prezenta și vom interpreta tabelele mai importante din output.

Tabelul *Model Summary* prezintă, pentru fiecare dintre cele trei modele :

- coeficienții de corelație multiplă R , coeficienții de determinare R^2 , coeficienții de determinare ajustați și erorile standard ale estimatorilor ; valorile lui R^2 cresc odată cu creșterea numărului de VI incluse în model, astfel că în cazul unui model cu mai multe VI vom lua în considerare valoarea lui $R^2_{ajustat}$.

R^2 reprezintă proporția de varianță din VD explicată de către VI (combinația liniară a VI). Ajustarea lui R^2 se calculează în funcție de mărimea eșantionului și numărul de predictor, $R^2_{ajustat}$ fiind un estimator mai corect al lui R^2 în populație. Formula de calcul este :

$$R^2_{ajustat} = 1 - \frac{(1 - R^2)(N - 1)}{N - p - 1}$$

Atunci când volumul eșantionului (N) este mare, iar numărul de predictorii (p) e redus, ajustarea lui R^2 este destul de redusă. În schimb, atunci când volumul eșantionului este redus, iar numărul de predictorii este mare, $R^2_{ajustat}$ va fi mult mai mic comparativ cu R^2 .

- coeficienții R^2 schimbare (notați ΔR^2 , reprezentând schimbările lui R^2 odată cu trecerea de la un model la altul) și rezultatele la testele F de verificare a semnificației acestor schimbări.

Constatăm că modelul 2 are coeficientul de determinare ajustat cel mai ridicat (0,471), creșterea față de modelul 1 $\Delta R^2 = 0,045$ fiind semnificativă ($p < 0,01$). Astfel, modelul 2 explică 47,1% din variația variabilei *aptitudini de leadership*, cu 4,5% mai mult decât modelul 1, această creștere fiind semnificativă statistic ($p = 0,005$). Reamintim că modelul 1 conținea VI *inteligenta emotionala* și *dominanta*, iar modelul 2 adaugă la acestea și VI *atitudine proactiva*. În schimb, dacă mai adăugăm și VI *autoeficienta* (cazul modelului 3), coeficientul de determinare R^2 ajustat scade cu 0,04%, astfel încât, în loc să mărim eficiența explicativă a modelului de regresie, o scădem. Prin urmare, modelul explicativ cel mai bun este modelul 2.

Model Summary^d

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics				
					R Square Change	F Change	df1	df2	Sig. F Change
1	.665 ^a	.442	.430	3,41	.442	38,382	2	97	.000
2	.698 ^b	.487	.471	3,28	.045	8,376	1	96	.005
3	.700 ^c	.490	.469	3,29	.004	.720	1	95	.398

- a. Predictors: (Constant), *dominanta*, *inteligenta emotionala*
 b. Predictors: (Constant), *dominanta*, *inteligenta emotionala*, *atitudine proactiva*
 c. Predictors: (Constant), *dominanta*, *inteligenta emotionala*, *atitudine proactiva*, *autoeficienta*
 d. Dependent Variable: *aptitudini de leadership*

Tabelul *ANOVA* testează eficiența fiecăruia dintre cele trei modele de regresie; observăm că toate cele trei modele sunt semnificative.

ANOVA^d

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	890,134	2	445,067	38,382	.000 ^a
	Residual	1124,776	97	11,596		
	Total	2014,910	99			
2	Regression	980,396	3	326,799	30,326	.000 ^b
	Residual	1034,514	96	10,776		
	Total	2014,910	99			
3	Regression	988,174	4	247,044	22,858	.000 ^c
	Residual	1026,736	95	10,808		
	Total	2014,910	99			

- a. Predictors: (Constant), *dominanta*, *inteligenta emotionala*
 b. Predictors: (Constant), *dominanta*, *inteligenta emotionala*, *atitudine proactiva*
 c. Predictors: (Constant), *dominanta*, *inteligenta emotionala*, *atitudine proactiva*, *autoeficienta*
 d. Dependent Variable: *aptitudini de leadership*

Tabelul *Coefficients* prezintă (pentru fiecare model în parte și fiecare VI) coeficienții de regresie standardizați și nestandardizați, eroarea standard a coeficienților nestandardizați, testele *t* pentru testarea ipotezei nule conform căreia coeficienții nestandardizați sunt zero, corelațiile zero-order, parțiale și semiparțiale și statisticile de coliniaritate *Tolerance* și *VIF*.

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	<i>t</i>	Sig.	Correlations			Collinearity Statistics	
		B	Std. Error	Beta			Zero-order	Partial	Part	Tolerance	VIF
1	(Constant)	8,667	2,448		3,541	,001					
	inteligenta emotionala	,321	,052	,482	6,152	,000	,571	,530	,467	,936	1,068
	dominanta	,551	,123	,351	4,478	,000	,473	,414	,340	,936	1,068
2	(Constant)	2,213	3,247		,682	,497					
	inteligenta emotionala	,270	,053	,406	5,073	,000	,571	,460	,371	,835	1,198
	dominanta	,454	,123	,289	3,680	,000	,473	,352	,269	,866	1,154
	atitudine proactiva	,215	,074	,238	2,894	,005	,494	,283	,212	,788	1,269
3	(Constant)	1,853	3,279		,565	,573					
	inteligenta emotionala	,270	,053	,406	5,069	,000	,571	,461	,371	,834	1,198
	dominanta	,450	,124	,287	3,642	,000	,473	,350	,267	,865	1,156
	atitudine proactiva	,178	,086	,197	2,058	,042	,494	,207	,151	,585	1,711
	autoeficienta	6,8E-02	,080	,075	,848	,398	,336	,087	,062	,686	1,458

a. Dependent Variable: aptitudini de leadership

Observăm că modelele de regresie 1 și 2 sunt cele în cazul cărora toate VI au coeficienți de regresie *b* semnificativ diferiți de zero. În cazul modelului 3, coeficientul de regresie *b* corespunzător variabilei *autoeficienta* nu mai este semnificativ ($p = 0,398$), prin urmare această variabilă nu aduce un plus explicativ. Un coeficient *b* arată cu cât crește VD atunci când VI corespunzătoare a crescut cu o unitate, în condițiile în care celelalte VI sunt constante.

Dacă coeficienții de regresie *b* sunt exprimați în valori ale VI respective (fapt ce nu ar permite o comparare între ei, ca mărime a influenței/explicației asupra VD), coeficienții de regresie beta sunt standardizați și permit astfel compararea. Semnul coeficienților *b* și beta indică sensul influenței VI asupra VD; dacă semnul unui coeficient beta este negativ, atunci variabila corespunzătoare acestui coeficient are un efect negativ asupra VD. În modelul 1, *inteligenta emotionala* are o influență mai mare asupra VD (beta = 0,482), comparativ cu *dominanța* (beta = 0,351). La fel, în modelul 2, cea mai mare influență asupra VD o are *inteligenta emoțională* (beta = 0,406), urmată de *dominanță* (beta = 0,289) și apoi de *atitudinea proactivă* (beta = 0,238). Cu cât un coeficient beta este mai îndepărtat de zero, cu atât VI corespunzătoare are un efect mai puternic asupra VD. Totuși, ar fi greșit să spunem pe baza comparării coeficienților beta că *inteligenta emotionala* explică de două ori mai mult din varianța VD, comparativ cu *atitudinea proactiva*. O asemenea comparare este permisă doar pe baza coeficienților *Part* ridicați la pătrat (r_{sp}^2), cum vom vedea mai jos. Astfel, $r_{sp}^2 \text{ inteligenta emoțională} = 0,14$, iar $r_{sp}^2 \text{ atitudine proactivă} = 0,04$, ceea ce înseamnă că în cazul modelului 2, *inteligenta emoțională* are o influență de aproximativ trei ori mai mare asupra VD, comparativ cu *atitudinea proactivă*.

Coeficientul de corelație semiparțială r_{sp} pentru o nouă variabilă introdusă în model (de exemplu, variabila *atitudine proactivă* în modelul 2) va fi egal cu $\sqrt{R^2_{schimbare}}$ calculat pentru modelul respectiv. Astfel,

$$r_{sp\_atitudine\_proactiva} = \sqrt{0,045} = 0,212$$

Să verificăm statisticile de coliniaritate. Pentru evitarea multicoliniarității trebuie ca valorile *Tolerance* ale fiecărei VI dintr-un model să fie mai mari decât $1 - R^2_{ajustat}$ (Leech, Barrett și Morgan, 2005, p. 95). Observăm că în cazul modelului 3 valoarea *Tolerance* pentru *atitudine proactivă* este cea mai scăzută (0,585) și apropiată de valoarea limita permisă, $1 - R^2_{ajustat} = 1 - 0,469 = 0,531$. Totuși, condiția de evitare a multicoliniarității este îndeplinită pentru fiecare dintre cele trei modele.

În calcularea toleranței sunt luate în calcul numai VI, VD fiind exclusă din calcule. Astfel, pentru fiecare VI, $toleranța = 1 - R^2_i$, unde R^2_i este pătratul corelației multiple dintre o VI și celelalte VI. De exemplu, în cazul modelului 2, pentru a calcula toleranța variabilei *dominanta* vom calcula $R^2_{dominanta}$ realizând un model de regresie în care *dominanta* este VD, iar VI sunt *inteligenta emoțională* și *atitudinea proactivă*. Găsim că $R^2_{dominanta} = 0,134$ și prin urmare toleranța pentru variabila *dominantă* este $1 - R^2_{dominanta} = 1 - 0,134 = 0,866$. Astfel, dacă toleranța pentru o VI este ridicată, aceasta înseamnă că R^2 pentru acea variabilă este scăzut, rezultă că respectiva variabilă este explicată într-o proporție foarte scăzută de celelalte VI – ceea ce era de dorit pentru validitatea modelului. În cazul invers, când toleranța este scăzută, R^2 este ridicat, respectiva VI este explicată într-o proporție mare de celelalte VI, ceea ce încalcă condiția 4 de evitare a multicoliniarității (coliniaritatea reprezintă de fapt o relație liniară puternică între VD).

VIF (*variance inflation factor*) este reciproca toleranței, $VIF = \frac{1}{tolerance}$.

Corelațiile *Zero-order* sunt coeficienții de corelație Pearson între VI și VD, iar corelațiile *Partial* sunt corelațiile parțiale dintre VI și VD (controlând celelalte VI din model). În schimb, corelațiile *Part* indică valorile corelațiilor semiparțiale dintre fiecare VI și VD (și reprezintă relația dintre VI respectivă și partea din VD care nu este explicată de alte VI din model), sunt notate cu r_{sp} și reprezintă efectul izolat al unei VI asupra VD; prin urmare se poate calcula coeficientul de determinare specific relației dintre acea VI și VD, r^2_{sp} (Sava, 2004, pp. 222-223). Astfel, în cazul modelului 2, putem spune că 14% ($0,371^2$) din varianța variabilei *aptitudini de leadership* poate fi explicată prin diferențele interindividuale în ceea ce privește *inteligenta emoțională* a acelorași subiecți.

Urmărind acum coeficienții corespunzători VI *atitudine proactivă* și *autoeficiență* din modelul 3 în scopul eliminării uneia dintre aceste două variabile din model, observăm că deși în cazul atitudinii proactive valoarea toleranței este cea mai scăzută, totuși corelația semiparțială dintre *autoeficiență* și VD este extrem de mică (0,062), ceea ce înseamnă că această variabilă ar trebui exclusă – alegere susținută și de valoarea mai scăzută a coeficientului de corelație Pearson (sau zero-order) dintre *autoeficiența* și VD.

20.4. Mărimea efectului


Indicatori ai mărimii efectului în regresia liniară multiplă sunt :

- R^2 ajustat, reprezentând o mărime a efectului global, în cazul întregului model (a acțiuni combinate a tuturor VI incluse în model) ;
- coeficienții de corelație semiparțiali r_{sp} (coloana *Part* din tabelul *Coefficients*), aceștia fiind indicatori ai mărimii efectului fiecărei VI asupra VD. În cazul modelului 2, mărimea efectului variabilei *dominanță* este $r_{sp} = 0,34$ etc.


20.5. Verificarea asumpțiilor

Verificarea condițiilor 3 și 6 se face prin inspectarea graficelor de mai jos.

- *Histograma* reziduurilor standardizate de mai jos (*Histogram*) indică faptul că acestea sunt normal distribuite (condiția 3).




- *Normal P-P Plot* (graficul *Normal P-P Plot of Regression* de mai jos) verifică normalitatea distribuției reziduurilor standardizate prin comparație cu abaterile de la curba normală ; observăm că este îndeplinită condiția 3, de normalitate a distribuției reziduurilor. Verificarea statistică a condiției 3 se poate face și prin intermediul testului Kolmogorov-Smirnov sau Shapiro-Wilk aplicat în cazul variabilei nou create în baza de date *Standardized Residual (zre_1)*.



- *Scatterplot*-ul de mai jos verifică îndeplinirea condiției 6; în cazul homoscedasticității punctele din grafic trebuie să nu urmeze un anumit pattern și să fie împrăștiate aleatoriu în jurul valorilor zero. În situația noastră, condiția 6 este îndeplinită.


Scatterplot




Pentru verificarea condiției 5 (evitarea valorilor extreme și a cazurilor influente) urmărim tabelul *Residuals Statistics*.

Identificarea unor posibile cazuri extreme (cazuri care pot afecta stabilitatea ecuației de regresie) se face urmărind valorile minime și maxime ale reziduurilor standardizate (calculate prin diferite metode) *Std. Residual* și *Stud. Residual*; dacă valorile minime sau maxime depășesc 3 în valoare absolută, atunci există probabilitatea existenței unor cazuri extreme. Când mai mult de 1% dintre cazuri se află în afara intervalului $[-3, +3]$ sau mai mult de 5% se află în afara intervalului $[-2, +2]$, ecuația de regresie nu este stabilă (Field, 2000, p. 154). Constatăm că valoarea maximă pentru *Std. Residual* este 2,090, iar pentru *Stud. Residual* este 2,104, valori ce depășesc intervalele menționate,

ceea ce înseamnă că există cazuri extreme în baza de date. Pentru a identifica aceste cazuri extreme vom activa meniul *Data* → *Sort Cases*.



Trecem variabila nou creată *zre_1* în câmpul *Sort by*, alegem opțiunea *Descending* din câmpul *Sort Order* pentru ca valorile variabilei selectate să fie ordonate ascendent (deoarece știm că valorile maxime ale *Std. Residual* depășesc intervalele permise și ca atare pe acestea încercăm să le identificăm) și clic *OK*.



Valorile din baza de date vor arăta astfel :

File Edit View Data Transform Analyze Graphs Utilities Window Help										
1 : zre_1	2,08973528658617									
	nrsb	alider	lemotion	domin	aproact	autoefic	zre_1	sre_1	coo_1	
1	44	38	48	13	47	31	2,08974	2,10409	,01221	
2	83	36	46	12	48	28	1,79066	1,81023	,01440	
3	50	38	55	10	50	35	1,68010	1,71975	,02824	
4	68	34	41	12	42	40	1,66874	1,75417	,06463	

Constatăm că există doar un singur caz extrem, având valoarea 2,08974, la variabila *zre_1*, iar această valoare îi corespunde subiectului cu numărul de ordine 44.

Verificarea existenței unor cazuri influente (care pot afecta valorile coeficienților de regresie, în sensul că odată cu eliminarea respectivului caz coeficienții de regresie se modifică substanțial) se face cel mai ușor inspectând distanța lui Cook : dacă valoarea

acestua este mai mare decât 1, atunci cazul respectiv are o influență ridicată asupra modelului de regresie (Field, 2000, p. 155). Cum valoarea maximă a distanței lui Cook este 0,065, nu există cazuri influente și prin urmare condiția 5 este îndeplinită. Pentru identificarea cazurilor influente procedăm ca în situația cazurilor extreme, activând meniul *Data* → *Sort Cases* și ordonând baza de date în funcție de variabila *coo_1*.

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	20,93	36,24	29,53	3,16	100
Std. Predicted Value	-2,723	2,125	,000	1,000	100
Standard Error of Predicted Value	,38	1,34	,71	,19	100
Adjusted Predicted Value	20,92	36,47	29,53	3,18	100
Residual	-6,45	6,87	-3,62E-15	3,22	100
Std. Residual	-1,961	2,090	,000	,980	100
Stud. Residual	-1,979	2,104	,000	1,003	100
Deleted Residual	-6,56	6,96	6,51E-04	3,38	100
Stud. Deleted Residual	-2,010	2,144	,000	1,009	100
Mahal. Distance	,357	15,342	3,960	2,700	100
Cook's Distance	,000	,065	,010	,012	100
Centered Leverage Value	,004	,155	,040	,027	100

a. Dependent Variable: aptitudini de leadership

20.6. Prezentarea rezultatelor

Pentru a verifica eficiența unor modele explicative a *aptitudinilor de leadership* pe baza variabilelor *inteligenta emotionala*, *atitudine proactiva* și *dominanta*, am aplicat metoda regresiei liniare multiple ierarhice. Mediile, deviațiile standard și corelațiile între variabile sunt prezentate în tabelul 20.1. Rezultatele arată că modelul 2 conținând variabilele *inteligenta emotionala*, *dominanta* și *atitudine proactiva* explică cel mai bine aptitudinile de leadership, contribuția tuturor celor trei variabile fiind semnificativă. Astfel, indivizii care au nivele înalte de inteligență emoțională, dominanță și atitudine proactivă tind să aibă dezvoltate aptitudinile de leadership. În cazul modelului 2, $R^2_{\text{ajustat}} = 0,47$, ceea ce înseamnă că modelul 2 explică 47% din varianța aptitudinilor de leadership, efectul global fiind de nivel ridicat (cf. Cohen, 1988). De asemenea, ponderea explicativă cea mai mare dintre cele trei variabile ale modelului 2 o are inteligența emoțională, urmată de dominanță și atitudine proactivă (tabelul 20.2). Indicatorii mărimii efectului pentru fiecare dintre cele trei variabile din modelul 2 sunt $r_{sp} = 0,37$ pentru inteligență emoțională, $r_{sp} = 0,27$ pentru dominanță și $r_{sp} = 0,21$ pentru atitudine proactivă, efectele fiind de nivel mediu (inteligență emoțională) și slab (dominanță și atitudine proactivă) (cf. Cohen, 1988).

Tabelul 20.1. Indicatorii descriptivi și matricea de corelații pentru variabilele conținute în modelele de regresie

Variabila	M	SD	1	2	3	4	5
1. Aptitudinile de leadership	29,53	4,51	–	0,571**	0,473**	0,494**	0,336**
2. Inteligența emoțională	45,19	6,79		–	0,253*	0,386**	0,217*
3. Dominanța	11,57	2,87			–	0,341**	0,219*
4. Atitudinea proactivă	45,93	5,01				–	0,560**
5. Autoeficiența	30,89	4,97					–

Notă. $R^2 = 0,44$ pentru modelul 1; $\Delta R^2 = 0,045$ pentru modelul 2 ($ps < 0,01$); $\Delta R^2 = 0,004$ pentru modelul 3 ($ps > 0,05$); * $p < 0,05$; ** $p < 0,01$

Tabelul 20.2. Rezultatele analizei de regresie ierarhice vizând explicarea aptitudinilor de leadership pe baza VI luate în studiu ($N = 100$)

Variabile	B	SE B	β
Modelul 1			
Inteligența emoțională	0,32	0,05	0,48**
Dominanța	0,55	0,12	0,35**
Modelul 2			
Inteligența emoțională	0,27	0,05	0,41**
Dominanța	0,45	0,12	0,29**
Atitudinea proactivă	0,22	0,07	0,24**
Modelul 3			
Inteligența emoțională	0,27	0,05	0,41**
Dominanța	0,45	0,12	0,29**
Atitudinea proactivă	0,18	0,09	0,20*
Autoeficiența	0,07	0,08	0,08

Notă. $R^2 = 0,44$ pentru modelul 1; $\Delta R^2 = 0,045$ pentru modelul 2 ($ps < 0,01$); $\Delta R^2 = 0,004$ pentru modelul 3 ($ps > 0,05$); * $p < 0,05$; ** $p < 0,01$

Exerciții SPSS

Regresia liniară

1. Să presupunem că tocmai am adaptat testul de inteligență Stanford-Binet (SB) pe populație românească. Ne propunem să verificăm validitatea criterială a acestui test prin corelarea sa cu un test de inteligență deja adaptat, WISC. Stabiliți ecuația de regresie și preziceți QI-ul unui individ la testul WISC, știind că a obținut un QI de 112 la testul S-B. Baza de date este *Validitate_test_QI*.
2. Analizăm influența motivației elevilor asupra performanțelor școlare ale acestora. Luând în calcul că un mediu familial optim poate influența performanța școlară, ne propunem să controlăm această influență măsurând două tipuri de relații părinți-copii, bazate pe oferirea suportului parental și a autonomiei. În aceste condiții, vom verifica în ce măsură motivația elevilor explică performanțele lor, izolând factorii suport și autonomie parentală. Baza de date este *Model_explicativ*.

Capitolul 21. Fidelitatea (Reliability Analysis)

21.1. Prezentare generală

Fidelitatea unei scale sau test se referă la gradul de precizie (încredere, consistență și stabilitate) cu care scala măsoară o anumită caracteristică. Astfel, fidelitatea unui instrument este dată de gradul de încredere pe care-l avem în acel instrument, în stabilitatea, consistența sa internă și temporară. Practic, nu putem spune despre o scală că este fidelă sau nu, așa cum nu putem spune despre un eșantion că este reprezentativ sau nu: o scală este mai mult sau mai puțin fidelă, valoarea coeficientului de fidelitate calculat indicându-i un anumit grad de fidelitate.

Există mai multe metode prin care se poate verifica fidelitatea testelor, fiecareia corespunzându-i un coeficient de fidelitate (Stan, 2002, Havârneanu, 2000, Rotaru, Iluș, 1999, Radu, 1993): 1) metoda consistenței interne (metoda alfa Cronbach); 2) metoda test-retest; 3) metoda testelor (formelor) paralele; 4) metoda înjumătățirii testului; 5) metoda interevaluatori. Atunci când ne vom referi la fidelitatea unei scale vom preciza metoda folosită și valoarea coeficientului de fidelitate obținut. În literatura de specialitate se consideră că o scală sau test are o fidelitate bună atunci când coeficientul de fidelitate este mai mare de 0,70 și o fidelitate foarte bună atunci când coeficientul de fidelitate este mai mare de 0,80. În continuare vom discuta metoda alfa Cronbach, de verificare a consistenței interne și coeficientul alfa Cronbach.

Coeficientul de consistență internă alfa Cronbach pentru scale/teste cu mai mulți itemi este cel mai frecvent folosit coeficient de fidelitate și e prezentat în orice studiu în partea de final a descrierii scalei respective. Acest coeficient indică consistența interitemi a scalei analizate și este bazat pe o medie a corelațiilor dintre itemii scalei.

Scopul aplicării metodei este în general verificarea fidelității unei scale prin metoda consistenței interne, însă în practică se folosește și ca etapă în alegerea itemilor pentru construirea unei scale care să măsoare un construct psihologic.

Condiții: 1) fiecare item al scalei măsoară același construct; 2) variantele de răspuns la fiecare item sunt măsurate fie pe scale Likert, fie prin răspunsuri dihotomice (da/nu, adevărat/fals).


Exemple. 1) Verificăm fidelitatea scalei stimei de sine (Rosemberg) prin calcularea coeficientului de consistență internă alfa Cronbach. 2) Verificăm consistența internă a unei scale construite pentru a măsura abilitățile de leadership.

21.2. Analiza fidelității scalelor


Să analizăm fidelitatea subscalei *comunicare verbală* din scala abilităților de comunicare prezentată în cadrul subcapitolului destinat analizei factoriale. Deschideți fișierul *Analiza_factoriala*. Știm deja că subscalea conține itemii c1, c2, c4, c7, c11, c12 și c14,

iar itemii 7 și 11 sunt codificați invers. Vom recodifica mai întâi itemii c7 și c11 prin procedura *Transform* → *Recode* → *Into Different Variables*, noile variabile fiind rec7 pentru itemul c7 și rec11 pentru itemul c11.

Calea în SPSS pentru calcularea coeficientului alfa Cronbach este : *Analyze* → *Scale* → *Reliability Analysis*.



Trecem itemii c1, c2, c4, rec7, rec11, c12 și c14 în câmpul *Items* din partea dreaptă. Observăm că în câmpul din stânga-jos, *Model*, este selectat automat de SPSS *Alpha* (opțiunea standard pentru alfa Cronbach).



Activăm butonul *Statistics*, în câmpul *Descriptives for* bifăm opțiunile *Item*, *Scale* și *Scale if item deleted*, apoi în câmpul *Inter-item* selectăm opțiunea *Correlations*, apoi clic *Continue* și clic *OK*.

Reliability Analysis: Statistics

Descriptives for

- ☒ Item
- ☒ Scale
- ☒ Scale if item deleted

Inter-Item

- ☒ Correlations
- ☐ Covariances

Summaries

- ☐ Means
- ☐ Variances
- ☐ Covariances
- ☐ Correlations

ANOVA Table

- ☒ None
- ☐ F test
- ☐ Friedman chi-square
- ☐ Cochran chi-square

☐ Hotelling's T-square

☐ Tukey's test of additivity

☐ Intraclass correlation coefficient

Model: Type: Confidence interval: Test value:

Continue Cancel Help

Vom analiza rezultatele obținute în continuare.

21.3. Interpretarea outputului

În prima parte a outputului sunt prezentate mediile și deviațiile standard pentru fiecare dintre cei șapte itemi analizați (urmare a selectării opțiunii *Descriptives for Item*).

R E L I A B I L I T Y A N A L Y S I S - S C A L E (A L P H A)				
		Mean	Std Dev	Cases
1.	C1	5.2719	1.5980	114.0
2.	C2	5.3158	1.5871	114.0
3.	C4	5.0789	1.6730	114.0
4.	REC7	5.0614	1.7155	114.0
5.	REC11	4.8070	1.7991	114.0
6.	C12	5.2807	1.4483	114.0
7.	C14	5.1316	1.5826	114.0

Urmează matricea corelațiilor dintre itemi (efect al selectării opțiunii *Inter-item Correlations*). Observăm că majoritatea coeficienților de corelație depășesc valoarea 0,40 și că fiecare item are corelații ridicate cu ceilalți itemi (dacă un item nu ar corela cu alți itemi decât foarte slab, atunci probabil acel item ar trebui înlăturat din scală).

Correlation Matrix							
	C1	C2	C4	REC7	REC11	C12	C14
C1	1.0000						
C2	.5416	1.0000					
C4	.4950	.4338	1.0000				
REC7	.4329	.4674	.3313	1.0000			
REC11	.2862	.3315	.4255	.3766	1.0000		
C12	.4332	.2729	.5824	.3100	.3368	1.0000	
C14	.6996	.6563	.5007	.4435	.3385	.5127	1.0000

Următoarea parte din output prezintă media, varianța și deviația standard pentru întreaga subscală (efect al selectării opțiunii *Scale*).

Statistics for	Mean	Variance	Std Dev	N of Variables
Scale	35.9474	67.1476	8.1944	7

În ultima parte a outputului sunt prezentate elementele cele mai importante ale analizei (efect al selectării opțiunii *Scale if item deleted*), deoarece sunt indicatori ai relației dintre fiecare item și scala totală. Prima coloană prezintă media scalei atunci când eliminăm unul dintre itemi. A doua coloană prezintă varianța scalei în urma eliminării itemului respectiv. Următoarele trei coloane sunt cele mai importante, deoarece sunt indicatori ai adecvării itemilor pentru scala respectivă.

Coloana *Corrected Item-Total Correlation* prezintă corelația dintre fiecare item și suma celorlalți itemi din scală (scorul total la scală dacă înlăturăm itemul respectiv). Acești coeficienți de corelați, sunt coeficienții de corelație Pearson dintre scorul la un item și suma scorurilor celorlalți itemi. Dacă această corelație este moderat ridicată sau ridicată (peste 0,40, de exemplu), atunci itemul are corelații bune cu ceilalți itemi și spunem despre itemul respectiv că este o componentă bună a scalei. Itemii care în această coloană au corelații scăzute (mai mici de 0,30) sau negative vor fi înlăturați sau studiați și reformulați dacă vizăm un nou studiu de dezvoltare a scalei. De fapt, un item care are o corelație corectată¹ scăzută cu totalul scalei nu măsoară același construct cu ceilalți itemi din scală. Observăm că, în cazul nostru, toți itemii au corelații corectate cu scala de valoare bună și foarte bună, itemul rec11 având corelația cea mai scăzută (0,46), deci fiecare item măsoară același construct cu ceilalți itemi din scală.

Coloana *Squared Multiple Correlation* reprezintă pătratul corelației multiple dintre item și toți ceilalți itemi (este coeficientul R^2 din regresia multiplă având itemul respectiv ca VD și toți ceilalți itemi ca VI). Astfel, coeficientul 0,53 al itemului c1 ne spune că scorurile unui subiect la itemul c1 sunt prezise în proporție de 53% de scorurile subiectului la toți ceilalți itemi. Observăm că itemul c11, care avea cea mai scăzută corelație corectată cu totalul scalei, are de asemenea și cel mai scăzut coeficient de corelație multiplă la pătrat (0,25).

1. Se numește corelație corectată, deoarece din scorul total la scală a fost înlăturat scorul la itemul respectiv.

Ultima coloană, *Alpha if Item Deleted*, prezintă valoarea coeficientului alfa Cronbach în urma înlăturării itemului respectiv din scală. Observați în partea de jos a tabelului valoarea coeficientului alfa pentru întreaga scală, $\alpha = 0,8426$ și, de asemenea, valoarea coeficientului alfa standardizat $\alpha_{\text{standardizat}} = 0,8454$, ultimul neinteresându-ne momentan. Astfel, dacă am înlătura itemul c1 din scală, valoarea lui alfa ar scădea de la 0,8426 la 0,8108, ceea ce nu ar fi de dorit. Observați că dacă am înlătura din scală un item care are o corelație corectată foarte mare (de exemplu, itemul c14 care are o corelație corectată de 0,7339), coeficientul alfa ar scădea la 0,8002. *Regula* este următoarea: studiem coeficienții din ultima coloană și dacă observăm în cazul unuia dintre itemi o valoare mult mai ridicată decât coeficientul alfa general, atunci vom elimina itemul respectiv din scală și reaplicăm procedura (există cazuri în care alfa general este, de exemplu, 0,40, iar în urma eliminării unuia dintre itemi din scală alfa crește la 0,70). În mod clar, dacă în urma eliminării unui item din scală alfa crește semnificativ, atunci acel item nu măsoară același construct cu ceilalți itemi din scală.

În general, folosim valoarea alfa nestandardizat în prezentarea fidelității scalei. Dacă însă există diferențe mari între mediile itemilor și deviațiile standard ale acestora, vom folosi valoarea lui alfa standardizat.

RELIABILITY ANALYSIS - SCALE (ALPH)					
Item-total Statistics					
	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item- Total Correlation	Squared Multiple Correlation	Alpha if Item Deleted
C1	30.6754	49.6371	.6642	.5353	.8108
C2	30.6316	50.5887	.6219	.5078	.8173
C4	30.8684	49.4604	.6327	.4716	.8153
REC7	30.8860	51.1108	.5338	.3145	.8311
REC11	31.1404	51.8031	.4675	.2562	.8429
C12	30.6667	53.3215	.5545	.4362	.8274
C14	30.8158	48.4702	.7339	.6460	.8002
Reliability Coefficients			7 items		
Alpha = .8426			Standardized item alpha = .8454		

Asemenea oricărui coeficient de fidelitate, valoarea coeficientului alfa trebuie să fie peste 0,70¹. Deoarece în formula de calcul a lui alfa intră și numărul de itemi din scală, odată cu creșterea numărului de itemi tinde să crească și valoarea coeficientului alfa.

1. Totuși, deseori, în jurnalele de specialitate întâlnim coeficienți alfa cu valori între 0,60 și 0,69.

21.4. Considerații finale

Observații :

1. Valorile obținute la alfa Cronbach în cazul itemilor măsurați prin scale dihotomice sunt în general mai mici comparativ cu valorile alfa pentru itemi măsurați prin scale Likert. Pedhazur și Pedhazur (1991) oferă un exemplu în acest sens : pentru 4 itemi măsurați pe o scală Likert în 7 trepte, $\alpha = 0,80$; după dihotomizarea aceluiași 4 itemi, $\alpha = 0,64$.
2. Dacă coeficientul alfa Cronbach este mai mare de 0,90, atunci există foarte probabil itemi care se repetă în conținut sau scala conține mai mulți itemi decât ar fi necesar (Leech, Barrett și Morgan, 2005).
3. Dacă în urma aplicării unei scale construite de alt autor constatăm o valoare alfa scăzută, însă observăm de asemenea că alfa crește substanțial în urma înlăturării unui item din scală, este indicat să înlăturăm itemul respectiv și să luăm în calcul doar ceilalți itemi rămași în scală în calcularea unui scor compozit la scală care va fi utilizată în viitoarele operații statistice.

Fidelitatea scăzută a scalelor (testelor) are consecințe negative în cazul :

1. *coeficientului de corelație.* Fidelitatea scăzută a uneia dintre scalele X și Y (sau a ambelor) tinde să scadă valoarea coeficientului de corelație dintre scalele X și Y (Pedhazur și Pedhazur, 1991 ; Schwab, 2005) ;
2. *regresiei simple.* Dacă X este VI și Y este VD, atunci o fidelitate scăzută a scalei X tinde să micșoreze valoarea coeficientului de regresie și să mărească valoarea interceptului (constantei). În schimb, o fidelitate scăzută a scalei Y are implicații asupra inferenței statistice, scăzând probabilitatea de a respinge ipoteza nulă (Schwab, 2005) ;
3. *regresiei multiple*, când există multicolinearitate între VI. Slaba fidelitate a unei VI are efecte în atenuarea, mărirea sau chiar schimbarea semnului coeficienților de regresie (standardizați sau nestandardizați) (Schwab, 2005) ;
4. *validității de construct.* Consistența internă ridicată a unei scale este o condiție necesară (nu și suficientă) a validității de construct a respectivei scale ;
5. *validității rezultatelor prezentate.* Deoarece fidelitatea este o condiție necesară (nu și suficientă) a validității, rezultatele obținute în urma aplicării unor scale sau teste care au o fidelitate scăzută vor prezenta de asemenea o slabă validitate pentru cercetătorii interesați din domeniu.

Exerciții SPSS

Analiza fidelității scalelor

1. Deschideți fișierul *Stima_de_sine*. Verificați fidelitatea scalei de stimă de sine.
2. Deschideți fișierul *Analiza_factoriala*. Verificați fidelitatea subscalei *comunicare gestuală*. Subscala conține itemii c3, c5, c9 și c13.
3. Deschideți fișierul *Intimitate_sociala*. Verificați fidelitatea scalei intimitate socială.

Capitolul 22. Analiza factorială exploratorie

22.1. Prezentare generală

În general, în cercetările din științele educației măsurăm un număr mare de variabile care să răspundă diferitelor obiective fixate. Corelațiile dintre aceste variabile pot fi aranjate într-o matrice corelațională¹ care pe diagonala principală va avea valorile 1, deoarece fiecare variabilă va corela perfect cu ea însăși. Urmărind această matrice corelațională, am putea observa existența unor grupări de variabile care corelează între ele. Existența mai multor variabile care corelează între ele ne sugerează că aceste variabile ar putea măsura diferite aspecte ale aceleiași dimensiuni subiacente. Astfel de dimensiuni subiacente sunt denumite *factori* sau *variabile latente*.

Distingem astfel între variabilele *manifeste*, *observabile* (direct măsurabile) și variabilele *latente*, *subiacente* unor variabile manifeste. Variabilele latente sau factor sunt variabilele care stau în spatele unor variabile manifeste. De exemplu, variabila măsurată direct prin răspunsul la un item de genul *Sunt o persoană vorbărească* este o variabilă observabilă. În schimb, variabila *sociabilitate* nu poate fi măsurată direct și prin urmare este o variabilă latentă, nemanifestă. Cu toate acestea, în spatele faptului că sunt sau nu o persoană vorbărească stă tocmai factorul *sociabilitate*. Analiza factorială permite tocmai descoperirea unui număr redus de factori sau variabile latente care pot explica un număr mare de variabile manifeste.

Analiza factorială este o *tehnică de reducere a datelor* folosită pentru a reduce un număr mare de variabile la un set redus de factori subiacenți care să exprime informațiile esențiale conținute în variabilele inițiale.

Scopul general al analizei factoriale este descoperirea unui număr redus de factori latenți care să reprezinte cât mai bine un număr mare de variabile observabile ce corelează între ele.

Direcțiile de aplicare ale analizei factoriale sunt multiple :

1. *analiza patternurilor* dintr-o matrice de corelații ;
2. *reducerea* unui număr mare de variabile la un număr redus de factori ;
3. *simplificarea analizei* unor variabile independente puternic corelate (situație care poate fi prezentă în cazul regresiei multiple sau a analizei de varianță multivariată) ;
4. *explorarea* unor variabile direct observabile pentru a verifica prezența unor variabile teoretice ; —
5. *analiza de item* în cazul construirii unor teste sau chestionare ;
6. *stabilirea validității de construct* a unor teste sau chestionare.

Există două tipuri majore de analiză factorială : analiza factorială exploratorie și analiza factorială confirmatorie. Dacă analiza factorială exploratorie se poate realiza prin

1. Vezi capitolul destinat analizei corelaționale.

intermediul majorității programelor statistice (inclusiv SPSS), analiza factorială confirmatorie poate fi aplicată doar prin anumite programe statistice specializate precum Amos, Lisrel, Mplus etc. (nu și prin SPSS!). Ca atare, vom discuta în continuare despre analiza factorială exploratorie.

22.2. Aspecte metodologice implicate în aplicarea analizei factoriale

Aplicarea analizei factoriale presupune o serie de *etape* :

1. verificarea condițiilor necesare aplicării analizei factoriale ;
2. alegerea tipului de metodă de extragere a factorilor și a tipului de rotație a factorilor ;
3. alegerea numărului de factori ce urmează a fi extrași ;
4. analiza saturațiilor factoriale și interpretarea factorilor.

22.2.1. Asumpții sau condiții ce trebuie îndeplinite pentru aplicarea analizei factoriale

Există un număr de condiții ce trebuie îndeplinite pentru aplicarea analizei factoriale (pentru a obține un model factorial valid și stabil).

22.2.1.1. Mărimea eșantionului de subiecți sau cazuri

Până nu demult, regula generală privind mărimea eșantionului în analiza factorială exploratorie era „cu cât mai mulți subiecți/cazuri, cu atât mai bine”. Recomandările explicite privind mărimea eșantionului variaau de la un autor la altul, toate având în vedere fie proporția de subiecți per variabilă, fie mărimea minimă a eșantionului. În mod tradițional, se considera că o proporție de 4 : 1 sau 5 : 1 de subiecți per variabilă conducea la un eșantion suficient. Coakes (2005) recomandă un minim de cinci subiecți per variabilă, menționând totodată că un eșantion de 100 de subiecți este acceptabil, iar un eșantion de peste 200 este preferabil. Gorsuch (1983, *apud* Flyod și Widaman, 1995) recomandă un minimum de 5 subiecți per variabilă sau un eșantion de cel puțin 200 de subiecți. Steiner (1994, *apud* Flyod și Widaman, 1995) recomandă 5 subiecți per variabilă atunci când eșantionul este de peste 100 de subiecți și 10 subiecți per variabilă atunci când eșantionul este mai mic de 100 de subiecți. Gorsuch (1997) sugerează că regula „10 subiecți/cazuri per variabilă” conduce la stabilirea unui volum al eșantionului minim acceptat.

Studiile mai complexe derulate de Guadagnoli și Velicer (1988) au arătat că saturațiile variabilelor în factori, mărimea acestor saturații, alături de mărimea eșantionului și numărul de indicatori per factor sunt foarte importante pentru determinarea unui model factorial valid și stabil. Astfel, dacă saturațiile factoriale sunt de 0,80, modelul factorial este stabil chiar și pentru eșantioane mai mici de 50 de subiecți. Dacă saturațiile factoriale sunt de 0,60, soluția factorială este stabilă pe eșantioane mai mari de 150 de subiecți; în cazul unor eșantioane mai mici de 150 de subiecți, pentru ca modelul

factorial să fie valid ar trebui ca fiecare componentă (factor) să conțină cel puțin 4 variabile cu saturații de 0,60 (adică factorii să fie bine determinați, definiți). În general, dacă saturațiile factoriale sunt de 0,40, avem nevoie de eșantioane mari, de 300-400 de subiecți. Totuși, chiar și în cazul unor saturații factoriale de 0,40, dacă avem cel puțin 10 variabile per factor atunci un eșantion de 150 de subiecți este suficient pentru a obține un model factorial valid.

Ulterior, MacCallum și colaboratorii săi (1999) au sugerat că mărirea eșantionului și proporția de variabile per factor depind de designul studiului, accentuând importanța valorilor comunalităților în obținerea unui model factorial valid. Ideea de bază era că odată cu scăderea valorilor comunalităților tinde să crească importanța mărimii eșantionului. Vom prezenta în continuare rezultatele obținute și recomandările autorilor studiului în cauză.

Atunci când comunalitățile sunt în medie peste 0,60, modelul factorial este stabil chiar și pe eșantioane mai mici (sub 100 de subiecți) *în condiția în care factorii sunt bine determinați* (respectiv când numărul de factori este redus, iar numărul de variabile per factor tinde să crească : de exemplu, de la un model având 10 variabile și 3 factori extrași la unul având 20 de variabile și 3 factori extrași); *dacă factorii sunt slab determinați* (de exemplu, un model având 20 variabile și 7 factori extrași), chiar și la o medie a comunalităților de peste 0,60 mărirea eșantionului trebuie să depășească 100 sau chiar 200 de subiecți pentru ca modelul factorial să fie stabil.

Odată cu scăderea valorilor comunalităților, rolul mărimii eșantionului și al bunei determinări a factorilor devine tot mai important. Dacă media comunalităților este peste 0,50, vom putea obține un model factorial stabil în condițiile în care : 1) factorii sunt bine determinați (dacă extragem un număr redus de factori, fiecare având cât mai multe variabile) și 2) mărirea eșantionului este între 100 și 200 de subiecți.

Atunci când comunalitățile au valori scăzute (majoritatea sau toate sub 0,50) și totuși factorii sunt bine determinați (6-7 variabile per factor și un număr redus de factori), putem obține un model factorial stabil doar dacă eșantionul conține peste 100 de subiecți. Însă dacă avem comunalități mici, un număr redus de factori având fiecare 3-4 variabile, pentru a obține un model factorial stabil e nevoie de eșantioane de peste 300 de subiecți. Situația cea mai puțin dezirabilă apare atunci când comunalitățile sunt mici, iar factorii sunt slab determinați ; pentru obținerea unui model factorial stabil e nevoie în acest caz de eșantioane de peste 500 de subiecți.

Prezentăm mai jos pentru cei interesați rezultatele analitice obținute de MacCallum și colaboratorii săi (1999) pentru a ilustra mai bine efectele mărimii eșantionului, valorilor comunalităților și ale bunei/slabei determinări a factorilor asupra obținerii unui model factorial stabil.

Tabelul 22.1. Procentele soluțiilor factoriale convergente și admisibile (stabile) în studiul Monte Carlo derulat de MacCallum *et al.* (1999)

Raportul variabile-factori și nivelul comunalităților	Mărirea eșantionului			
	60	100	200	400
10 variabile, 3 factori (factori bine determinați)				
Comunalități scăzute*	74,6	78,7	95,2	99,0
Comunalități medii**	99,0	98,0	99,0	98,0
Comunalități ridicate***	100	100	100	100

20 variabile, 3 factori (factori foarte bine determinați)

Comunalități scăzute	87,0	97,1	100	100
Comunalități medii	100	100	100	100
Comunalități ridicate	100	100	100	100

20 variabile, 7 factori (factori slab determinați)

Comunalități scăzute	4,1	15,8	45,9	80,7
Comunalități medii	16,5	42,9	72,5	81,3
Comunalități ridicate	39,7	74,6	91,7	97,1

* Comunalități luând valori de 0,2, 0,3 și 0,4

** Comunalități luând valori, în ordine, de la 0,2 la 0,8

*** Comunalități luând valori de 0,6, 0,7 și 0,8

Tot referitor la eșantion trebuie remarcat că dacă acesta este mult mai omogen comparativ cu populația, atunci acest fapt va avea efecte asupra restrângerii plajei de măsurare a variabilelor și prin aceasta va atenua mărimea corelațiilor dintre variabile, conducând ulterior în mod cronat la saturații factoriale mai reduse și chiar corelații între factori. Pe de altă parte, trebuie asigurată independența eșantionului față de variabilele măsurate. Așadar, vom evita fie omogenitatea eșantionului, fie eșantioanele a căror selecție este în legătură cu variabilele măsurate (Fabrigar *et al.*, 1999).

22.2.1.2. Adecvarea variabilelor în modelul factorial (este potrivită matricea corelațională pentru analiza factorială?)

Există mai multe metode pentru verificarea adecvării variabilelor la modelul factorial, printre care : inspectarea matricei de corelații, testul Barlett de sfericitate, indexul KMO și inspectarea matricei de covarianță antiimagine (Dziuban și Shirkey, 1974). Le vom discuta în detaliu în continuare.

1. *Inspectarea vizuală a matricei corelațiilor dintre variabile* ; dacă nu există corelații (peste 0,30) între variabile sau anumite seturi de variabile, atunci analiza factorială nu este indicată. Dacă itemii noștri măsoară aceeași dimensiune, atunci ne vom aștepta ca ei să coreleze unii cu alții (deoarece măsoară același lucru). Ne așteptăm ca variabilele care corelează să se regăsească în același factor, iar variabilele care nu corelează să se distribuie în factori diferiți. Dacă, inspectând matricea corelațională, observăm una sau mai multe variabile care nu corelează cu celelalte sau că aceste corelații sunt foarte slabe, atunci va trebui să excludem din analiza factorială variabilele în cauză. Obținerea matricei de corelații se face prin procedura *corelații* (vezi capitolul destinat analizei corelaționale).

2. *Testul Barlett de sfericitate* (rezultatele la acest test trebuie să fie semnificative). Dacă variabilele ar corela doar cu ele însele și nu ar corela deloc cu celelalte variabile, atunci matricea de corelații ar fi o matrice-identitate care ar avea 1 pe diagonală și 0 în rest. Testul Barlett verifică ipoteza nulă conform căreia matricea de corelații este o matrice-identitate ; dacă rezultatul la acest test este *semnificativ*, atunci putem respinge ipoteza nulă și accepta ipoteza de cercetare conform căreia matricea de corelații diferă de o matrice-identitate, ceea ce înseamnă că există anumite relații între variabile, iar acestea sunt potrivite pentru a aplica analiza factorială.

3. *Testul KMO (Kaiser-Meyer-Olkin)* de măsurare a adecvării (potrivirii) eşantionului de itemi pentru modelul factorial; acesta ia valori între 0 şi 1. Kaiser şi Rice (1974) recomandă evaluarea acestui index astfel:

valori peste 0,90	superbe
valori între 0,80 şi 0,90	foarte bune
valori între 0,70 şi 0,80	de medie
valori între 0,60 şi 0,70	mediocre
valori între 0,50 şi 0,60	mizerabile
valori sub 0,50	inacceptabile

Aşadar, indexul KMO trebuie să fie peste 0,50, în caz contrar nefiind indicată aplicarea analizei factoriale. Dziuban şi Shirkey (1974) sugerează că KMO poate creşte dacă: a) numărul de variabile creşte; b) numărul factorilor (reali) scade; c) mărimea eşantionului creşte şi d) nivelul general al corelaţiilor dintre variabile creşte. Toate aceste observaţii tind să fie valabile şi pentru rezultatul la testul Barlett de sfericitate, acesta fiind sensibil în special la mărimea eşantionului.

Testul KMO este calculat atât pentru verificarea adecvării *tuturor* variabilelor la model, cât şi pentru verificarea adecvării *fiecărei* variabile la model; în ultimul caz, valorile KMO sunt de fapt coeficienţii de pe diagonala principală a matricei antiimage a corelaţiilor, iar aceştia trebuie să fie peste 0,50 (în caz contrar variabila respectivă trebuie înlăturată din modelul factorial şi refăcută analiza factorială) (Field, 2000, p. 456).

4. *Inspectarea coeficienţilor din afara diagonalei principale în matricea de covarianţă antiimage* (aceştia trebuie să fie 0 sau cât mai aproape de 0). Dacă în această matrice nu există prea mulţi coeficienţi diferiţi de zero sub diagonala principală atunci matricea de corelaţii este potrivită pentru analiza factorială. Nu există o regulă pentru a decide dacă numărul de coeficienţi diferiţi de zero de sub diagonala principală este suficient de mare pentru a decide dacă datele sunt potrivite pentru analiza factorială sau nu; totuşi, Dziuban şi Shirkey (1974) sugerează că dacă 25% dintre aceşti coeficienţi sunt diferiţi de zero, atunci avem motive să ne îndoim că matricea corelaţională ar fi potrivită pentru analiza factorială.

22.2.1.3. Evitarea multicolinearităţii şi a singularităţii

Multicolinearitatea se referă la corelaţiile foarte ridicate (peste 0,80 sau 0,90) între variabile iar singularitatea (*singularity*) se referă la variabilele perfect corelate. Verificarea acestei condiţii se face prin calcularea determinantului matricei de corelaţii, iar valoarea acestuia trebuie să fie peste 0,00001; în caz contrar, există multicolinearitate sau singularitate şi trebuie ca în matricea de corelaţii să identificăm variabilele între care există corelaţii peste 0,80 pentru a proceda la eliminarea uneia (sau mai multora) dintre aceste variabile.

22.2.1.4. Independența variabilelor măsurate

Orice dependență în ceea ce privește măsurarea unor variabile poate conduce la creșterea corelațiilor dintre ele conducând astfel la regăsirea lor în același factor (Tinsley și Tinsley, 1987). Dependența poate apărea când un scor total și scorurile sale compozite sunt incluse în aceeași analiză factorială (includerea, de exemplu în aceeași analiză factorială a variabilelor QI total, QI verbal și QI de performanță). Un alt tip de dependență apare atunci când scorurile unor scale care au itemi în comun sunt incluse în analiza factorială. În exemplul dat de Tinsley și Tinsley (1987), scala gândirii introverte (conținând 43 de itemi) și scala orientării spre practică (conținând 30 de itemi) au 8 itemi comuni și o corelație de $-0,61$; prin urmare, asemenea scale nu trebuie incluse în aceeași analiză factorială. Dependența mai poate apărea și atunci când scalele sunt ipsative.

22.2.1.5. Alte condiții necesare pentru aplicarea analizei factoriale

Dacă primele trei condiții necesită verificări statistice mai complexe, există un număr de alte condiții mai simple de verificat pentru aplicarea analizei factoriale:

- Variabilele sunt normal distribuite: deși analiza factorială este robustă față de încălcarea acestei condiții, dacă variabilele analizate sunt normal distribuite soluția factorială va fi mult mai bună.
- Variabilele sunt măsurate prin scale Likert, scale de intervale sau proporții.
- Este presupusă existența unor variabile latente în spatele variabilelor manifeste analizate prin analiza factorială. În caz contrar, se aplică principiul GIGO (*garbage in, garbage out* – în engleză); nu putem introduce un amalgam de variabile fără legătură teoretică între ele și să obținem un set de factori valizi.

22.2.2. Optimizarea modelului factorial prin designul cercetării

Vom discuta în această secțiune despre modalitățile prin care putem contribui la obținerea unui model factorial stabil prin intermediul design-ului cercetării (altfel spus, înainte de analiza statistică a datelor).

Mai mulți autori au arătat că stabilitatea modelului factorial depinde de interacțiunea unor factori precum a) mărimea eșantionului, b) numărul de variabile per factor, c) calitatea variabilelor (calitatea măsurării acestora) d) mărimea comunalităților și e) mărimea saturațiilor factoriale (Guadagnoli și Velicer, 1988; Velicer și Fava, 1998; MacCallum *et al.*, 1999 etc.). Interacțiunea acestor factori permite ca existența unor deficiențe la nivelul unuia să poată fi remediate prin sporirea contribuției celorlalți factori astfel ca în final să obținem un model factorial valid.

1. Mărimea eșantionului este optimă (200-400 de subiecți), iar calitatea variabilelor este bună; Velicer și Fava (1998) recomandau, pe de o parte, un număr de minim 4-5 variabile per factor. Pe de altă parte, autorii atrăgeau atenția (în special în cazul construirii unor scale) asupra pierderii unor variabile în urma analizei (între 25% și 50%) din cauza slabei performanțe empirice a acestora sau a diferențelor dintre ceea ce ne așteptam și ceea ce obținem de fapt, recomandând un număr de 6-10 variabile inițiale per factor.

2. Mărimea eșantionului este optimă, iar factorii sunt foarte bine determinați, în aceste condiții chiar și efectul unor comunalități scăzute poate fi atenuat, modelul factorial fiind stabil (MacCallum, 1999).

3. Calitatea variabilelor este scăzută, ceea ce are efecte asupra obținerii unor saturații factoriale scăzute. Calitatea variabilelor ține de mai multe aspecte. Pe de o parte, scala de măsurare are un efect important, reducerea numărului de trepte reducând saturațiile factoriale obținute; cu cât mai fină este măsurarea, cu atât mai mari vor fi saturațiile. Dacă variabilele sunt măsurate prin scoruri la diferite chestionare atunci estimăm obținerea unor saturații ridicate. Pe de altă parte, dacă variabilele sunt măsurate pe scale Likert, saturațiile sunt mai scăzute; reducerea treptelor la scalele Likert conduce de asemenea la reducerea saturațiilor factoriale. În aceste condiții, Velicer și Fava (1998) recomandă o proporție de 10-20 de variabile per factor.

4. Eșantionul de subiecți de care dispunem este limitat din diferite motive. Una dintre soluții este creșterea numărului de variabile până la 30-60 astfel încât să ne permitem a le elimina ulterior pe cele cu saturații reduse sau moderate; vom avea astfel în instrumentul final un set de variabile care au saturații ridicate (Guadagnoli și Velicer, 1988; Velicer și Fava, 1998). Problema este că numărul de variabile nu poate depăși numărul de subiecți din eșantion. Creșterea bunei determinări a factorilor (puțini factori și un raport de variabile per factor ridicat) și existența unor comunalități de nivel mediu conduce de asemenea la o soluție factorială stabilă (MacCallum *et al.*, 1999).

5. Un eșantion de subiecți suficient de mare (300-400 de subiecți) poate compensa atât obținerea unor saturații factoriale scăzute, cât și numărul redus de variabile per factor (Guadagnoli și Velicer, 1988; Velicer și Fava, 1998).

22.2.3. Metoda de extragere folosită

În analiza factorială exploratorie există mai multe metode de extragere a factorilor. Cele mai des folosite metode sunt analiza componentelor principale (Principal component analysis – PCA) și analiza factorilor principali (Principal axis factoring – PAF). Diferența dintre cele două metode ține de faptul că PCA caută să reducă mai degrabă matematic un număr mare de variabile la un număr redus de factori (componente) fără ca analiza să fie centrată pe factorii latenți existenți, câtă vreme PAF analizează explicit varianța comună împărțită de itemi, fiind focusată pe identificarea factorilor latenți.

Deși în general ambele metode conduc la soluții factoriale apropiate, există și situații în care soluțiile factoriale sunt diferite. De exemplu, cele două metode conduc la rezultate diferite atunci când comunalitățile sunt scăzute (de exemplu, în jur de 0,40), numărul de variabile este redus (mai mic de 30), iar soluția factorială conține un număr redus de variabile per factor. Dacă numărul de variabile este peste 30, iar comunalitățile sunt ridicate (în jur de 0,70), diferențele dintre cele două metode sunt scăzute.

Pe de altă parte, există și argumente ce țin de rezultatele statistice raportate care-i determină pe specialiști să prefere în studiile realizate aplicarea PCA în defavoarea PAF. Aplicarea PCA conduce la saturații factoriale ale variabilelor în factori mai ridicate și un procent de varianță explicată de factori mai mare comparativ cu PAF. Pe baza de date pe care vom lucra în acest capitol, prin aplicarea metodei PCA vom obține un procent de varianță explicată de factori de 64,13%. Dacă vom relua analiza în întregime, însă vom

înlocui metoda PCA cu PAF, vom obține un procent de varianță explicată de 55,32%, ceea ce e evident mai puțin.


Dincolo de toate aceste asemănări și diferențe existente între cele două metode, cercetătorii optează cel mai frecvent pentru aplicarea PCA. Russell (2002) remarcă faptul că din 137 de articole publicate în *Personaly and Social Psychology Bulletin* în perioada 1996-2000 ce prezentau rezultatele obținute în urma aplicării analizei factoriale exploratorii, în 62% dintre acestea fusese aplicată metoda PCA și doar în 11 % metoda PAF (restul de 27% neprecizând metoda de extragere aplicată).


Alte metode de extragere a factorilor disponibile în SPSS sunt : metoda celor mai mici pătrate (*The least squares method*), metoda probabilității maxime (*The maximum likelihood method*), metoda de extragere factorială Alpha (*Alpha factoring*) și analiza imaginii (*Image factoring*) (o descriere a acestor metode poate fi găsită în Culic, 2004).

22.2.4. Metoda de rotație aplicată

După extragere se aplică o metodă de rotație care face ca factorii extrași să fie mult mai ușor de interpretat. Vom exemplifica efectul pozitiv al rotației asupra interpretabilității factorilor în continuare.

Să urmărim graficele de mai jos în care avem o reprezentare în plan bidimensional a soluțiilor factoriale obținute înainte de rotație și după rotație. Axa Ox corespunde factorului F1 (componenta 1), iar axa Oy corespunde factorului 2 (componenta 2). Cu cât este mai aproape un item în acest plan bidimensional de una dintre axe și mai departe de origine (intersecția axelor), cu atât mai bine definește factorul în cauză acel item. Atunci când un item se află la egală distanță de ambele axe, acel item are saturații factoriale de valori apropiate în ambii factori și prin urmare nu definește foarte bine nici unul dintre cei doi factori.





Dacă urmărim graficul *Component Plot*, itemii C3 și C9 înainte de rotație sunt cam la aceeași distanță de ambele axe, ceea ce presupune că nu definesc foarte bine nici unul dintre cei doi factori. După rotație însă (*Component Plot in Rotated Space*), cei doi itemi sunt mai aproape de axa OY și prin urmare definesc mai bine factorul F2. Același lucru poate fi observat și în cazul itemilor C7 și C11 : aceștia nu definesc clar înainte de rotație nici unul dintre cei doi factori, însă după rotație definesc clar factorul F1, fiind foarte aproape de axa OX. Faptul că se află la extrema negativă a axei OX ne arată că acești itemi au saturații negative în factorul F1. De asemenea, urmărind itemii C10 și C8 după rotație, observăm ca ei definesc factorul F2, saturația itemului C10 în factorul F2 fiind mai mare decât cea a itemului C8 (cu cât un item este mai departe de originea axelor, cu atât saturația sa factorială va fi mai mare în factorul pe care-l definește).

Metodele de rotație pot fi atât *ortogonale* (acestea nu permit ca factorii să fie corelați), cât și *oblice* (acestea permit ca factorii să fie corelați). O greșeală frecventă în rândul cercetătorilor este aceea de a crede că rotația oblică presupune din start obținerea unor corelații între factori, ceea ce este fals. În rotația oblică factorii extrași *pot corela*, însă *nu este obligatoriu să și coreleze* (putem obține o soluție factorială în care corelațiile dintre factori sunt foarte apropiate de zero).

Metodele de rotație ortogonale disponibile în SPSS sunt *Varimax*, *Quartimax* și *Equamax*, iar cele oblice sunt *Direct oblimin* și *Promax*. Cele mai des utilizate metode de rotație sunt *Varimax* (rotație ortogonală) și *Direct oblimin* (rotație oblică).

Alegerea uneia dintre cele două tipuri de rotații ține în special de bazele teoretice de care dispunem: dacă avem motive să credem că factorii ar putea fi corelați, atunci alegem rotația oblică *Direct Oblimin*, iar dacă factorii sunt necorelați alegem rotația ortogonală *Varimax*.

22.2.5. Numărul factorilor de reținut.

Reguli privind numărul factorilor extrași

Atunci când aplicăm analiza factorială, numărul maxim de factori care pot fi extrași este egal cu numărul de variabile observabile analizate. Totuși, scopul analizei factoriale este identificarea unui număr redus de factori care să explice cât mai bine variabilele analizate. În decizia privind numărul de factori extrași care să ne conducă la un model factorial cât mai valid ne vom raporta la o serie de criterii sau reguli.

1. *Criteriul lui Kaiser* – vom reține toți factorii care au valori *eigenvalue* peste 1 (regula K1). Acesta este criteriul selectat automat în SPSS. Astfel, SPSS va produce o soluție factorială care conține doar acei factori ale căror valori *eigenvalue* sunt peste 1. Deși procedura este simplă și obiectivă, din cauza criteriului mecanic de selectare a factorilor poate conduce la rezultate eronate. De exemplu, nu putem spune că un factor care are o valoare *eigenvalue* de 1,01 este important, iar unul cu o valoare *eigenvalue* de 0,99 nu este important. Regula K1 poate fie subestima, fie supraestima numărul de factori extrași.

Zwick și Velicer (1986) arătau că odată cu creșterea numărului de variabile, număr de factori reținuți conform regulii K1 tinde să crească, așadar acest criteriu are tendința de a supraestima numărul de factori extrași. Autorii sugerau că 1) un factor cu trei sau mai multe saturări ridicate și o valoare *eigenvalue* peste 1 poate fi considerat *factor major*; 2) un factor care are a) mai puțin de trei saturări ridicate însă o valoare *eigenvalue* peste 1 sau b) mai mult de trei saturări ridicate, însă o valoare *eigenvalue* mai mică decât 1 poate fi considerat un factor minor și 3) un factor care are mai puțin de trei saturări ridicate și o valoare *eigenvalue* sub 1 este un *factor slab*.

Stevens (2002, p. 390), trecând în revistă mai multe reguli de extragere a factorilor, recomandă aplicarea criteriului K1 atunci când: 1) numărul de variabile este mai mic decât 30, iar comunalitățile mai mari decât 0,70 sau 2) când volumul eșantionului este mai mare de 250 de subiecți, iar comunalitățile sunt mai mari de 0,60.

Studiind valorile *eigenvalue* corespunzătoare fiecărui factor din tabelul *Total Variance Explained* următor, constatăm că primului factor îi corespunde o valoare *eigenvalue* de 5,031, celui de-al doilea factor îi corespunde o valoare de 2,317, celui de-al treilea factor o valoare de 1,630, celui de-al patrulea factor o valoare de 0,892 etc., prin urmare, ar trebui extrași trei factori.


Total Variance Explained

Component	Initial Eigenvalues		
	Total	% of Variance	Cumulative %
1	5,031	35,936	35,936
2	2,317	16,547	52,483
3	1,630	11,644	64,127
4	,892	6,368	70,495
5	,765	5,465	75,960
6	,634	4,526	80,486
7	,557	3,976	84,463
8	,502	3,587	88,049
9	,449	3,211	91,260
10	,313	2,233	93,493
11	,286	2,042	95,535
12	,263	1,882	97,417
13	,223	1,590	99,007
14	,139	,993	100,000

Extraction Method: Principal Component Analysis.

2. *Criteriul lui Cattell* – ne vom raporta la graficul Scree al lui Cattell (*Scree Plot*) și vom alege să reținem factorii începând de la momentul în care apare platoul. Acest grafic conține pe axa OX factorii care pot fi extrași de la 1 (numărul minim) la 14 (numărul maxim, egal cu numărul de variabile analizate, în cazul de față), iar pe axa OY valorile *eigenvalue* pe care le poate lua fiecare factor. Pentru o mai bună vizualizare a criteriului, imaginați-vă pe grafic de la dreapta la stânga că urcați pe un munte: momentul în care începeți să urcați efectiv este momentul de decizie. În cazul de față ar trebui să reținem trei factori. Marea problemă a acestui criteriu este gradul ridicat de subiectivitate în luarea deciziei privind factorii reținuți.

Dacă saturațiile factoriale ale variabilelor în factori sunt ridicate, testul Scree al lui Cattell estimează mai corect numărul de factori comparativ cu regula K1, fiind mai corect și mai puțin variabil (Zwick și Velicer, 1986). Acuratețea criteriului lui Cattell nu este afectată de creșterea numărului de variabile analizate și nici de creșterea raportului de variabile per factor; în schimb, în situația în care saturațiile factoriale sunt scăzute, acuratețea acestui test tinde să scadă.



3. *Criteriul procentului de varianță cumulată explicată de toți factorii extrași*: Stevens (2002, p. 390) recomandă ca factorii extrași să explice cel puțin 70% din totalul varianței variabilelor originale. Henson *et al.* (2006), trecând în revistă articolele în care erau prezentate rezultatele unor studii de analiză factorială exploratorie din patru reviste importante (*Educational and Psychological Measurement*, *Journal of Educational Psychology*, *Personality and Individual Differences* și *Psychological Assessment*) publicate între anii 1999 și 2006, observau că procentul de varianță explicată era în medie doar de 52,03% din totalul varianței, fapt ce-i făcea să se întrebe asupra rezonabilității criteriului propus de către Stevens. În ceea ce ne privește, recomandăm ca varianța explicată de factorii extrași să fie mai mare de 40% (atunci când operăm cu variabile măsurate pe scale Likert), iar factorii extrași sunt consistenți teoretic.

4. *Criteriul componenței și interpretabilității factorilor*. Să presupunem că într-un model factorial decidem să reținem patru factori, însă constatăm că ultimul factor conține doar o singură variabilă cu saturație ridicată; în acest caz ar trebui reluată analiza urmând să verificăm o extragere a trei factori. Specialiștii recomandă în general un minim de trei variabile per factor. Guadagnoli și Velicer (1998), în urma unor studii de simulare Monte Carlo, au observat că o creștere a numărului de variabile per factor conduce la o soluție factorială mai stabilă și constatau următoarele:

- factorii ce conțin patru mai multe saturații peste 0,60 în valoarea absolută sunt stabili chiar și pe eșantioane mici;
- factorii ce conțin cel puțin 10 variabile, dar cu saturații relativ scăzute (în jur de 0,40) sunt stabili doar pe eșantioane de peste 150 de subiecți;
- factorii având puține variabile și saturații relativ scăzute sunt stabili doar pe eșantioane de peste 300 de subiecți.

Pe de altă parte, dacă ultimul factor extras este greu interpretabil vom renunța la acest model factorial și vom analiza un model cu mai puțini factori.

5. *Criteriul adecvării modelului teoretic la modelul empiric reprezentat de variabile*: procentul de reziduuri nonredundante mai mari decât 0,05 să fie sub 50% (în tabelul

Reproduced Correlation). Dacă într-un model factorial cu 2 factori procentul de reziduuri este peste 50%, iar în cel cu 3 factori procentul de reziduuri este sub 50%, atunci ar fi indicat să optăm pentru modelul cu 3 factori.

6. *Criteriul teoretic* : dacă scala a fost construită pe baza a 3 dimensiuni, atunci vom extrage 3 factori și nu mai mulți.


22.3. Aplicarea analizei factoriale

Vom analiza în continuare o scală construită să evalueze abilitățile de comunicare verbală și nonverbală (mimico-gestuală și emoțională)¹. Scala conține 14 itemi, iar răspunsurile sunt evaluate pe scale Likert în șapte trepte, de la 1 = „total dezacord” la 7 = „total de acord”. Scala a fost aplicată pe un lot de 114 subiecți și a fost construită urmărind trei dimensiuni – comunicare verbală, comunicare mimico-gestuală și comunicare emoțională –, itemii fiind următorii :


- C1: Sunt o persoană vorbărească.
- C2: Deseori, inițiez discuții cu colegii.
- C3: În discuțiile cu ceilalți am o mimică și o gestică exuberante.
- C4: Îmi exprim cu ușurință opiniile.
- C5: Când discut cu cineva îmi însoțesc cuvintele de gesturi.
- C6: Vocea îmi exprimă sentimentele de bucurie sau tristețe pe care le încerc.
- C7: Nu vorbesc prea mult cu colegii. (item inversat)
- C8: Îmi manifest cu ușurință emoțiile în discuțiile pe care le am.
- C9: Obişnuiesc să gesticulez atunci când vorbesc cu alții.
- C10: Îmi exprim fizic emoțiile.
- C11: Îmi este greu să-mi exprim gândurile în cuvinte. (item inversat)
- C12: Îmi este destul de ușor să-mi expun punctele de vedere într-o conversație.
- C13: Când comunic îmi accentuez ideile prin voce, mimică sau gestică.
- C14: Întru în discuțiile cu ceilalți relativ ușor.

Deschideți fișierul *Analiza_factoriala*. Calea de obținere a analizei factoriale în SPSS este: *Analyze* → *Data Reduction* → *Factor*.

1. Scala este construită de autor.



Trecem itemii C1-C14 din partea stângă în câmpul din dreapta, *Variables*.



Activăm butonul *Descriptives*. Opțiunile prezente aici ne permit verificarea condițiilor de aplicare ale analizei factoriale. Vom bifa opțiunile: *Coefficients*, *Determinant*, *KMO* and *Barlett's test of sphericity*, *Reproduced*, *Anti-image*.

- Opțiunea *Univariate descriptives* ne oferă informații privind variabilele analizate, respectiv mediile și abaterile standard (nu ne interesează în cazul de față).
- Opțiunea *Coefficients* realizează matricea de corelații dintre variabile, permițându-ne să verificăm dacă variabilele corelează între ele și mărimea acestor corelații; dacă vom bifa și *Significance levels*, matricea corelațională va conține și pragul de semnificație al fiecărei corelații.

- Opțiunea *Determinant* ne permite să verificăm multicolinearitatea și singularitatea variabilelor. Valoarea determinantului va trebui să fie mai mare decât 0,00001 pentru a evita multicolinearitatea și singularitatea variabilelor analizate; dacă determinantul este mai mic decât această valoare atunci va trebui să inspectăm matricea de corelații și să găsim acele variabile care corelează foarte puternic (peste 0,8), urmând să eliminăm una sau mai multe dintre acestea.
- Opțiunea *KMO and Barlett's test of sphericity* calculează indexul KMO de apreciere a adecvării eșantionului de itemi pentru modelul factorial și rezultatul la testul de sfericitate Barlett care verifică dacă matricea corelațională diferă de o matrice identitate (în care toți coeficienții de corelație dintre variabile ar fi zero – caz în care variabilele nu ar fi potrivite pentru aplicarea analizei factoriale).
- Opțiunea *Reproduced* ne permite să verificăm potrivirea modelului factorial teoretic cu cel real reprezentat de variabile. În partea superioară a tabelului (*Reproduced Correlation*) sunt prezentați coeficienții de corelație ideali între variabile în ipoteza unei potriviri perfecte a modelului factorial la variabilele selectate, pe diagonală fiind trecute comunalitățile pentru fiecare variabilă. În partea inferioară a tabelului (*Residual*) sunt prezentate reziduurile pentru fiecare corelație, calculate prin diferența dintre corelația reală și cea ideală; ar trebui să existe cât mai puține reziduuri cu valori peste 0,05. Din fericire, SPSS calculează și procentul de reziduuri care sunt mai mari de 0,05, iar acest procent ar trebui să fie mai mic de 50% pentru o adecvare cât mai bună a variabilelor la modelul factorial. O adecvare perfectă (respectiv un procent de reziduuri de 0% peste valoarea 0,05) se obține atunci când numărul de factori extrași este egal cu numărul de variabile analizate, altfel spus atunci când fiecare variabilă este un factor în sine.
- Opțiunea *Antiimage* realizează matricile de covarianță și corelație antiimage pentru a verifica potrivirea individuală a fiecărei variabile la modelul factorial (indicatorii KMO pentru fiecare variabilă); acești coeficienți se regăsesc pe diagonală principală și trebuie să fie peste 0,5 (ne vor interesa în special cei din partea superioară a tabelului, în câmpul *Antiimage Correlation*). Dacă în cazul unei variabile indicatorul KMO este sub 0,5 va trebui să luăm în calcul eliminarea acelei variabile din modelul factorial. De asemenea, coeficienții de sub diagonală principală vor trebui să fie foarte mici.

Factor Analysis: Descriptives

Statistics

- ☐ Univariate descriptives
☒ Initial solution

Continue

Cancel


Help

Correlation Matrix

- ☒ Coefficients ☐ Inverse
☐ Significance levels ☒ Reproduced
☒ Determinant ☒ Anti-image
☒ KMO and Bartlett's test of sphericity


Activăm butonul *Extraction*.

- În câmpul *Method* sunt prezentate diferite metode de extragere a factorilor, cele mai des utilizate fiind analiza în componente principale (Principal components analysis – PCA, opțiunea standard în SPSS) și analiza în factori principali (Principal axis factoring – PAF). Deși există unele diferențe între aceste două metode, ambele conduc la rezultate relativ similare. Opțiunea pentru una dintre cele două metode diferă de la autor la autor (Leech, Barrett și Morgan, 2005 ; Sava, 2004 ; Field, 2000 etc.). În ceea ce ne privește, vom opta pentru analiza în componente principale (vom lăsa selectată opțiunea standard, *Principal components*).
- În câmpul *Analyze* avem două opțiuni : fie analizăm matricea de corelație, fie matricea de covarianță. Matricea de corelație este varianta standardizată a matricei de covarianță și este selectată automat în SPSS (vom lăsa selectată opțiunea *Correlation matrix*). Selectarea opțiunii *Correlation matrix* este utilă în special când variabilele factorizate sunt măsurate prin scale diferite de măsurare (nu este cazul aici, deoarece toate variabilele sunt măsurate prin scala Likert în șapte trepte) sau, în situația în care variabilele, chiar măsurate prin aceleași scale, au variante foarte diferite – fapt care ar afecta negativ rezultatele obținute prin analiza în componente principale (Field, 2000, p. 448). Vom lăsa selectată opțiunea *Correlation matrix*.
- În câmpul *Display* selectăm *Scree plot* (testul Scree al lui Cattell – unul dintre criteriile pentru alegerea numărului de factori reținuți) și folosim opțiunea implicită *Unrotated factor solution*.
- În câmpul *Extract* avem două opțiuni privind numărul de factori extrași. Dacă lăsăm selectată opțiunea *Eigenvalues over* și luăm în considerație recomandarea lui Kaiser *eigenvalues over 1* (opțiunea implicită în SPSS), atunci vor fi reținuți doar acei factori care au *eigenvalues* peste 1. Dacă însă avem informații preliminare privind numărul de factori care ar trebui extrași, atunci bifăm opțiunea *Number of factors* și specificăm numărul de factori ce vor fi extrași ; în cazul de față vom trece cifra „3”, deoarece scala a fost construită având trei dimensiuni, apoi și clic *Continue*.




Activăm butonul *Rotation*.

- Există mai multe metode de rotație a factorilor, unele ortogonale (*Varimax*, *Quartimax* și *Equamax*), altele oblice (*Direct oblimin* și *Promax*). Cele mai des utilizate metode de rotație sunt *Varimax* (rotație ortogonală) și *Direct oblimin* (rotație oblică). Alegerea uneia dintre cele două rotații ține de bazele teoretice de care dispunem: dacă avem motive să credem că factorii (dimensiunile latente) sunt corelați atunci alegem rotația oblică *Direct Oblimin*, iar dacă factorii sunt necorelați alegem rotația ortogonală *Varimax*. Metoda *Varimax* conduce la obținerea unor factori care pot fi cu ușurință interpretați, fiind preferată de către majoritatea cercetătorilor. De cele mai multe ori, specialiștii recomandă într-o primă fază aplicarea metodei de rotație *Varimax*, apoi reluarea analizei factoriale prin aplicarea metodei *Direct oblimin* și compararea în final a soluțiilor factoriale obținute prin cele două metode. Dacă soluțiile factoriale obținute prin cele două metode nu diferă prea mult atunci va fi preferată metoda de rotație *Varimax*. Dacă însă soluțiile factoriale diferă într-o măsură semnificativă, atunci va trebui să regândim alegerea uneia dintre metodele de rotație, iar dacă dispunem de suficiente argumente pentru a presupune corelarea factorilor vom opta pentru metoda *Direct oblimin*, în caz contrar rămânând să alegem metoda *Varimax*. În situația de față, vom selecta metoda de rotație *Varimax*.
- *Observație*: dacă avem motive să presupunem existența unui singur factor general, vom aplica metoda *Quartimax*.
- Opțiunea *Rotated solution* implicită este extrem de importantă pentru interpretarea soluțiilor factoriale finale.
- Opțiunea *Loading plot(s)* conduce la o dispunere grafică a variabilelor analizate într-un spațiu bidimensional (atunci când extragem doi factori) sau tridimensional (atunci când extragem trei sau mai mulți factori), axele respectivului spațiu fiind reprezentate de factorii extrași. În cazul extragerii a mai mult de trei factori, spațiul tridimensional în care vor fi reprezentate variabilele va avea ca axe de raportare primii trei factori ca importanță. Această opțiune este viabilă în special atunci când extragem doi factori, deoarece ne ajută să vizualizăm mai bine cum se grupează variabilele în cei doi factori. Variabilele care au saturații ridicate în doar unul dintre cei doi factori vor fi reprezentate grafic mai aproape de axa corespunzătoare factorului respectiv; dacă o variabilă are saturații factoriale aproximativ apropiate ca mărime în amândoi factorii, atunci ea va fi reprezentată la distanță egală de factorii respectivi (situație care nu este dezirabilă pentru o bună soluție factorială).
- Opțiunea *Maximum Iteration for Convergence* reprezintă numărul de momente în care SPSS va căuta o soluție optimă și este setat automat în SPSS la 25. Dacă numărul de variabile este ridicat (de exemplu, peste 20), atunci pot fi mai greu găsite soluțiile factoriale optime (mai ales în cazul rotațiilor oblice), iar această valoare ar putea fi modificată cu 30 (Field, 2000, p. 451).



Butonul *Scores* permite salvarea scorurilor factoriale în baza de date ca variabile (estimarea acestora se face prin una dintre cele trei metode prezente : Regression, Barlett și Anderson-Rubin), însă în general nu optăm pentru operarea cu scoruri factoriale, ci cu dimensiuni sumate (se adună itemii corespunzători factorului respectiv și se obține un scor). În cazul nostru, dacă vom reține trei factori, vom aduna itemii corespunzători dimensiunii comunicare verbală, apoi pe cei corespunzători dimensiunii comunicare gestuală și apoi itemii corespunzători dimensiunii comunicare emoțională și vom obține un scor pentru factorul *comunicare verbală*, un scor pentru factorul *comunicare gestuală* și, de asemenea, un scor pentru factorul *comunicare emoțională*. Nu vom bifa nimic în cadrul acestei ferestre de dialog.




Activăm butonul *Options*.

- În câmpul *Missing Values* dispunem de trei opțiuni (putând opta doar pentru una dintre ele), acestea fiind specifice situațiilor în care un subiect a omis să răspundă la unul dintre itemi, de exemplu. Opțiunea *Exclude cases listwise* va exclude din toate analizele orice subiect sau caz care are un răspuns-lipsă la una dintre variabile. Opțiunea *Exclude cases pairwise* va exclude subiectul sau cazul care are o valoare lipsă la una dintre variabile doar din analizele care implică acea variabilă. Opțiunea *Replace with mean* va înlocui valoarea-lipsă a unui subiect sau caz la o variabilă cu media scorurilor la acea variabilă, păstrând astfel subiectul sau cazul respectiv în toate analizele ulterioare. Vom lăsa selectată opțiunea standard setată în SPSS – *Exclude cases listwise*.
- În câmpul *Coefficient Display Format* dispunem de două opțiuni care ne vor ajuta să vizualizăm mai bine soluția factorială găsită. Vom selecta mai întâi opțiunea *Sorted*

by size astfel că, în cadrul fiecărui factor, itemii vor fi așezați în ordinea descrescătoare a saturației lor în respectivul factor.

- Selectăm de asemenea opțiunea *Suppress absolute values less than*, iar acolo vom trece 0,40 (pragul minim luat în calcul pentru saturațiile itemilor în factori este în general 0,30).



22.4. Interpretarea outputului

Tabelul *Correlation Matrix* prezintă matricea corelațiilor dintre variabile; observăm că există mai multe seturi de corelații peste 0,30, prin urmare aplicarea analizei factoriale asupra variabilelor în cauză este potrivită. Ne așteptăm ca variabilele care corelează puternic să se regăsească în același factor, iar variabilele care nu corelează să se regăsească în factori diferiți. Observăm că nu există coeficienți de corelație peste 0,80, ca atare nu există variabile care să coreleze foarte puternic între ele (evitarea multicolarității). În partea din stânga jos a tabelului este trecută valoarea determinantului, Determinant = 0,000752 (E-04 ne spune că trebuie să trecem virgula în stânga peste 4 cifre). Cum determinantul este mai mare decât 0,00001 (în cazul de față 0,000752) rezultă că nu există multicolaritate sau singularitate între variabile.

Correlation Matrix^a

	C1	C2	C3	C4	C5	C6	C7
Correlation C1	1,000	,542	,298	,495	,236	,189	-,433
C2	,542	1,000	,230	,434	,164	,200	-,467
C3	,298	,230	1,000	,252	,632	,145	,015
C4	,495	,434	,252	1,000	,280	,064	-,331
C5	,236	,164	,632	,280	1,000	,098	-,083
C6	,189	,200	,145	,064	,098	1,000	-,053
C7	-,433	-,467	,015	-,331	-,083	-,053	1,000
C8	,107	,116	,291	,115	,066	,448	-,031
C9	,350	,232	,690	,215	,816	,225	-,134
C10	,227	,138	,451	,144	,310	,456	,074
C11	-,286	-,331	-,164	-,426	-,122	,012	,377
C12	,433	,273	,236	,582	,275	-,027	-,310
C13	,368	,381	,524	,437	,655	,117	-,268
C14	,700	,656	,341	,501	,263	,256	-,444

a. Determinant = 7,520E-04

Tabelul *KMO and Bartlett's Test* prezintă rezultatele la testele Bartlett și KMO. Observăm că pentru testul de sfericitate Bartlett $\chi^2(91) = 773,218$, $p < 0,001$ și, prin urmare, matricea de corelații diferă semnificativ de matricea-identitate în care variabilele nu ar corela între ele, variabilele fiind adecvate pentru factorizare. Indexul KMO = 0,817 caracterizează setul de variabilele ca fiind foarte bun pentru analiza factorială.

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,817
Bartlett's Test of Sphericity	Approx. Chi-Square	773,218
	df	91
	Sig.	,000

Tabelul *Anti-image Matrices* prezintă o serie de coeficienți pentru evaluarea adecvării variabilelor la modelul factorial. Vom inspecta jumătatea inferioară a tabelului, respectiv diagonala principală a câmpului *Anti-image Correlation*; dacă pe această diagonală principală apar valori sub 0,50, atunci itemul căruia îi corespunde acea valoare are o slabă adecvare pentru modelul factorial și trebuie înlăturat. În cazul nostru, observăm că pentru itemul C1 coeficientul este 0,862, pentru C2 este 0,830 etc., iar prin raportare la criteriul de evaluare a coeficienților KMO propus de Kaiser și Rice (1974), acești coeficienți sunt foarte buni, ceea ce arată că sunt potriviți pentru analiza factorială.

Anti-Image Matrices

	C1	C2	C3	C4	C5	C6
Anti-image Covariance						
C1	,433	-4,32E-02	-2,20E-02	-8,26E-02	3,465E-02	-6,86E-03
C2	-4,32E-02	,470	-2,59E-02	-5,78E-02	1,713E-02	-2,94E-02
C3	-2,20E-02	-2,59E-02	,421	5,109E-03	-5,67E-02	7,903E-02
C4	-8,26E-02	-5,78E-02	5,109E-03	,475	-6,70E-02	1,959E-02
C5	3,465E-02	1,713E-02	-5,67E-02	-6,70E-02	,261	9,964E-04
C6	-6,86E-03	-2,94E-02	7,903E-02	1,959E-02	9,964E-04	,682
C7	9,464E-02	,108	-,128	-5,68E-03	-3,37E-03	-1,75E-02
C8	8,030E-02	1,203E-02	-7,52E-02	-2,45E-02	7,179E-02	-,151
C9	-3,83E-02	2,537E-02	-7,55E-02	8,258E-02	-,150	-2,31E-02
C10	-7,13E-02	-9,30E-04	-5,71E-02	-5,64E-02	1,643E-03	-,120
C11	-2,41E-02	5,290E-02	6,809E-02	,142	-5,40E-03	-2,44E-02
C12	-3,46E-02	,113	5,481E-03	-,170	4,594E-03	6,024E-02
C13	3,250E-02	-8,28E-02	-4,06E-02	-6,41E-02	-7,44E-02	-6,80E-03
C14	-,143	-,157	-2,90E-02	-1,09E-02	2,602E-02	-7,35E-02
Anti-image Correlation						
C1	,862 ^a	-,959E-02	-5,14E-02	-,182	,103	-1,26E-02
C2	-,959E-02	,830 ^a	-5,83E-02	-,122	4,891E-02	-5,20E-02
C3	-5,14E-02	-5,83E-02	,879 ^a	1,143E-02	-,171	,148
C4	-,182	-,122	1,143E-02	,823 ^a	-,190	3,444E-02
C5	,103	4,891E-02	-,171	-,190	,774 ^a	2,361E-03
C6	-1,26E-02	-5,20E-02	,148	3,444E-02	2,361E-03	,788 ^a
C7	,184	,202	-,254	-1,06E-02	-8,46E-03	-2,72E-02
C8	,166	2,387E-02	-,158	-4,84E-02	,191	-,248
C9	-,124	7,868E-02	-,247	,255	-,624	-5,94E-02
C10	-,162	-2,03E-03	-,132	-,123	4,812E-03	-,218
C11	-4,34E-02	9,147E-02	,124	,244	-1,25E-02	-3,50E-02
C12	-7,44E-02	,234	1,197E-02	-,350	1,274E-02	,103
C13	7,797E-02	-,191	-9,87E-02	-,147	-,230	-1,30E-02
C14	-,380	-,401	-7,81E-02	-2,77E-02	8,914E-02	-,156

a. Measures of Sampling Adequacy(MSA)

Tabelul *Communalities* prezintă în coloana *Extraction* comunalitățile corespunzătoare fiecărei variabile după extragerea celor trei factori. Comunalitatea unei variabile (notată h^2) este pătratul coeficientului de corelație multiplă dintre variabilă și factori (R^2 din regresia multiplă în care variabila este VD, iar factorii sunt VI) și reprezintă proporția din varianța acelei variabile explicată de factorii extrași. Astfel, în cazul itemului C1, comunalitatea este de 0,620, ceea ce înseamnă că cei trei factori extrași explică 62% din varianța itemului C1. Cu cât o variabilă are o comunalitate mai ridicată, cu atât tinde să fie mai potrivită pentru modelul factorial ales, însă criteriul principal în evaluarea păstrării variabilei în modelul factorial este coeficientul de saturație al acesteia în factori (saturație care trebuie să fie cât mai ridicată).

Communalities		
	Initial	Extraction
C1	1,000	,620
C2	1,000	,593
C3	1,000	,698
C4	1,000	,553
C5	1,000	,833
C6	1,000	,612
C7	1,000	,514
C8	1,000	,660
C9	1,000	,829
C10	1,000	,744
C11	1,000	,369
C12	1,000	,527
C13	1,000	,699
C14	1,000	,726

Extraction Method: Principal Component Analysis.

Tabelul *Total Variance Explained* este unul dintre cele mai importante, deoarece conține valorile eigenvalue¹ pentru fiecare factor, procentele de varianță explicată de fiecare factor extras, precum și procentele de varianță cumulată explicată de toți factorii extrași înainte și după rotație. Astfel, factorul 1 explică 35,94% din varianța itemilor, factorul 2 explică 16,55% din varianța itemilor, factorul 3 explică 11,64% din varianța itemilor iar în total cei trei factori explică un total de 64,13% din varianța totală a itemilor. Eigenvalue reprezintă varianța explicată de fiecare factor din totalul varianței itemilor. Matematic, valoarea eigenvalue pentru un factor este egală cu suma pătratelor saturațiilor din acel factor (suma pătratelor corelațiilor dintre factor și variabile). Procentul de varianță explicată de un factor este egal cu valoarea eigenvalue a celui factor împărțită la numărul total de itemi și înmulțit cu 100 [de exemplu, procentul de varianță explicată de factorul 1 este $35,936\% = (5,031/14) \cdot 100$].


1. Deși în traducere expresia „valori eigenvalue” este pleonasm, o vom folosi pentru a păstra termenul englezesc ce apare în SPSS pentru o mai bună înțelegere.

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	5,031	35,936	35,936	5,031	35,936	35,936	3,672	26,228	26,228
2	2,317	16,547	52,483	2,317	16,547	52,483	3,154	22,531	48,759
3	1,630	11,644	64,127	1,630	11,644	64,127	2,152	15,369	64,127
4	,892	6,368	70,495						
5	,765	5,465	75,960						
6	,634	4,526	80,486						
7	,557	3,976	84,463						
8	,502	3,587	88,049						
9	,449	3,211	91,260						
10	,313	2,233	93,493						
11	,286	2,042	95,535						
12	,263	1,882	97,417						
13	,223	1,590	99,007						
14	,139	,993	100,000						

Extraction Method: Principal Component Analysis.

Graficul *Scree* prezentat mai jos (*Scree Plot*) este unul dintre criteriile la care ne raportăm atunci când decidem câți factori vor fi extrași. Graficul conține pe axa OX numărul total de factori care ar putea fi extrași (egal cu numărul de variabile, 14 în acest caz), iar pe axa OY valorile eigenvalue corespunzătoare fiecărui factor. Urmărind graficul observăm că factorii coboară până la un anumit nivel, după care urmează un platou – în cazul nostru, începând de la factorul 4 inclusiv urmează platoul. Unii autori sugerează să extragem numărul de factori existenți chiar înainte de acest platou (3 în acest caz), în vreme ce alții sugerează că vom reține factorii până la începerea platoului inclusiv (4 în acest caz).



În tabelul *Reproduced Correlations* este analizată adecvarea modelului cu trei factori la modelul empiric reprezentat de variabile.

Reproduced Correlations

	C1	C2	C3	C4	C5
Reproduced Correlation					
C1	,620 ^b	,599	,290	,566	,253
C2	,599	,593 ^b	,196	,538	,143
C3	,290	,196	,698 ^b	,271	,727
C4	,566	,538	,271	,553 ^b	,288
C5	,253	,143	,727	,288	,833 ^b
C6	,234	,239	,219	8,017E-02	2,682E-02
C7	-,505	-,514	-1,99E-02	-,485	-,873E-03
C8	,212	,208	,274	5,587E-02	8,289E-02
C9	,328	,224	,759	,318	,806
C10	,205	,165	,489	7,065E-02	,342
C11	-,432	-,426	-8,28E-02	-,433	-,102
C12	,494	,456	,273	,520	,343
C13	,435	,346	,628	,453	,709
C14	,671	,647	,324	,609	,280
Residual ^a					
C1		-5,71E-02	8,710E-03	-7,07E-02	-1,67E-02
C2	-5,71E-02		3,408E-02	-,104	2,173E-02
C3	8,710E-03	3,408E-02		-1,86E-02	-9,54E-02
C4	-7,07E-02	-,104	-1,86E-02		-8,25E-03
C5	-1,67E-02	2,173E-02	-9,54E-02	-8,25E-03	
C6	-4,56E-02	-3,99E-02	-7,42E-02	-1,60E-02	7,082E-02
C7	7,181E-02	4,665E-02	3,536E-02	,154	-7,43E-02
C8	-,105	-9,26E-02	1,690E-02	5,928E-02	-1,68E-02
C9	2,231E-02	8,090E-03	-6,83E-02	-,103	1,023E-02
C10	2,208E-02	-2,74E-02	-3,78E-02	7,335E-02	-3,17E-02
C11	,146	9,494E-02	-8,10E-02	6,992E-03	-2,03E-02
C12	-6,03E-02	-,183	-3,67E-02	6,237E-02	-6,84E-02
C13	-6,70E-02	3,558E-02	-,104	-1,60E-02	-5,43E-02
C14	2,883E-02	9,097E-03	1,686E-02	-,108	-1,69E-02

Extraction Method: Principal Component Analysis.

a. Residuals are computed between observed and reproduced correlations. There are 41 (45,0%) nonredundant residuals with absolute values > 0.05.

b. Reproduced communalities

În jumătatea superioară a tabelului (în câmpul *Reproduced Correlations*) sunt prezentați coeficienții de corelație dezirabili (între itemi) pentru o adecvare perfectă a modelului cu trei factori (cazul nostru) la cei 14 itemi, pe diagonală fiind trecute comunalitățile itemilor (din tabelul *Communalities*). În jumătatea inferioară (în câmpul *Residual*) sunt prezentate reziduurile pentru fiecare corelație dintre itemi, calculate prin diferența dintre corelația reală și corelația dezirabilă. De exemplu, pentru corelația dintre itemii C1 și C8,

$$Residual_{C1-C8} = r_{observată} - r_{model} = 0,107 - 0,212 = -0,105$$

Verificarea adecvării se face prin procentul de reziduuri nonredundante mai mari decât 0,05; în cazul nostru, procentul este de 45% (nota a din tabelul *Reproduced Correlations*).

Pentru o adecvare cât mai bună procentul trebuie să fie cât mai mic. O adecvare perfectă (procent 0%) obținem atunci când numărul de factori extrași este egal cu numărul de variabile. În cazul unui model cu doi factori am fi obținut un procent de 64%. Regula este ca procentul de reziduuri nonredundante mai mari de 0,05 să fie sub 50%. Observăm că modelul cu trei factori este mai potrivit pentru datele noastre decât un model cu doi factori (în primul caz procentul de 45% < 50%, în al doilea caz procentul de 64% > 50% și deci mai puțin indicat).

Tabelul *Component Matrix* prezintă saturațiile factoriale ale itemilor în factori înainte de rotație. De obicei, acest tabel nu ne interesează, deoarece soluția factorială după rotație (prezentată în tabelul *Rotated Component Matrix*) este mai ușor interpretabilă și ne vom concentra atenția asupra acesteia. Există însă și situații în care soluția factorială înainte de rotație este aceeași cu cea obținută după rotație, caz în care tabelul *Rotated Component Matrix* nu va mai fi prezentat în cadrul outputului.

Tabelul *Rotated Component Matrix* este unul dintre cele mai importante tabele din outputul analizei factoriale. Observăm că factorul F1 grupează itemii C14, C2, C1, C7, C4, C12 și C11, factorul F2 grupează itemii C5, C9, C3 și C13, iar factorul F3 grupează itemii C8, C10 și C6. În acest tabel, saturațiile itemilor în factori reprezintă corelația dintre item și factor. Astfel, saturația 0,787 a itemului C14 în factorul F1 reprezintă coeficientul de corelație Pearson dintre itemul C14 și factorul F1. Urmărind compoziția itemilor din cei trei factori îi vom putea defini astfel: factorul F1 se referă la comunicarea verbală, factorul F2 la comunicarea gestuală, iar factorul F3 la comunicarea emoțională.

Rotated Component Matrix^a

	Component		
	1	2	3
C14	,787		
C2	,737		
C1	,734		
C7	-,713		
C4	,703		
C12	,633		
C11	-,599		
C5		,908	
C9		,870	
C3		,787	
C13		,741	
C8			,807
C10			,777
C6			,776

Extraction Method: Principal Component Analysis.

Rotation Method: Varimax with Kaiser Normalization.

a. Rotation converged in 5 iterations.

Ultimul tabel, *Component Transformation Matrix*, nu este important pentru interpretarea rezultatelor la analiza factorială atunci când aplicăm metoda de rotație *Varimax*, el atrăgându-ne atenția doar în cazul aplicării metodei de rotație *Direct Oblimin*.

Dacă am fi aplicat metoda de rotație *Direct Oblimin*, rezultatele principale (comunalități, eigenvalue, varianță explicată, graficul Scree) ar fi fost aproximativ aceleași ca în cazul rotației *Varimax*, excepție făcând faptul că după rotație, în locul unei singure matrice (*Rotated Component Matrix*) vom dispune de două: *Pattern Matrix* și *Structure Matrix*.

Tabelele *Pattern Matrix* și *Structure Matrix* conțin soluția factorială pentru o extragere a trei factori (componente) după rotația oblică; în rotația ortogonală, cele două matrice sunt identice și se regăsesc sub denumirea de *Rotated Component Matrix*. De obicei, tabelul *Pattern Matrix* este mai ușor de interpretat, iar atenția cercetătorilor se concentrează asupra acestuia. Observăm că factorul F1 grupează itemii C14, C7, C2, C1, C4, C11 și C12, factorul F2 grupează itemii C5, C9, C3, C13, iar factorul F3 grupează itemii C8, C6 și C10. Comparând această soluție factorială cu cea obținută în urma aplicării metodei de rotație *Varimax* observăm că este identică; prin urmare ambele metode de rotație produc același rezultat în cazul de față.

Să analizăm cele două tabele. Tabelul *Pattern Matrix* conține saturații factoriale care corespund coeficienților de regresie multiplă Beta atunci când itemul ar fi VD iar factorii ar fi VI (faptul că în factorul F2 nu apare nici o saturație corespunzătoare itemului C14 înseamnă de fapt că această saturație este inferioară valorii 0,40, iar noi specificaserăm în opțiuni să fie afișate doar saturațiile peste 0,40). Astfel, saturația de 0,777 a itemului C14 în factorul F1 din tabelul *Pattern Matrix* reprezintă efectul direct al factorului F1 asupra itemului C14, menținând constantă influența factorilor F2 și F3 asupra itemului C14.

Pattern Matrix^a

	Component		
	1	2	3
C14	,777		
C7	-,749		
C2	,749		
C1	,726		
C4	,686		
C11	-,612		
C12	,604		
C5		,943	
C9		,873	
C3		,789	
C13		,723	
C8			,810
C6			,784
C10			,748

Extraction Method: Principal Component Analysis.

Rotation Method: Oblimin with Kaiser Normalization.

a. Rotation converged in 8 iterations.

În schimb, tabelul *Structure Matrix* conține saturații factoriale ce corespund corelației de ordinul zero din regresia multiplă cu itemul ca VD și factorii ca VI (sau corelație Pearson între factor și item); așadar, saturația 0,819 a itemului C14 în factorul F1 reprezintă coeficientul de corelație dintre factorul F1 și itemul C14. Observați că itemii C7 și C11 au saturații negative în factorul 1, deoarece acești doi itemi sunt itemi cotați invers (acest lucru a fost specificat în prezentarea scalei).

Structure Matrix

	Component		
	1	2	3
C14	,819		
C1	,762		
C2	,748		
C4	,730		
C7	-,695		
C12	,665		
C11	-,596		
C5		,906	
C9		,902	
C3		,819	
C13	,490	,789	
C8			,812
C10		,448	,808
C6			,775

Extraction Method: Principal Component Analysis.
Rotation Method: Oblimin with Kaiser Normalization.

Ultimul tabel, *Component Correlation Matrix*, este un tabel al corelațiilor dintre factori; observăm între factorii F1 și F2 o corelație de 0,301 și de asemenea între factorii F2 și F3 o corelație de 0,209.

Component Correlation Matrix

Component	1	2	3
1	1,000	,301	6,884E-02
2	,301	1,000	,209
3	6,884E-02	,209	1,000

Extraction Method: Principal Component Analysis.
Rotation Method: Oblimin with Kaiser Normalization.

În cazul în care acest studiu de verificare a validității de construct este doar o parte dintr-o cercetare mai amplă, următorul pas va fi însumarea itemilor corespunzători fiecărui factor (după recodificarea prealabilă a itemilor inversați, dacă este cazul), obținând astfel un scor pentru dimensiunea comunicare verbală, un scor pentru dimensiunea comunicare gestuală și un scor pentru dimensiunea comunicare emoțională.

Observație: unii autori (Pedhazur și Schmelkin, 1991) recomandă aplicarea atât a rotației ortogonale, cât și a celei oblice, iar în cazul unei corelații foarte scăzute între factori în cazul rotației oblice, alegerea metodei de rotație ortogonale.

22.5. Analiza comunalităților

Comunalitățile ne arată cât de mult din varianța unei variabile este explicată de factorii extrași. Inițial, *toți* factorii posibili (egali cu numărul de variabile observabile) sunt analizați pentru a calcula comunalitățile variabilelor, iar aceștia explică toată varianța din variabilele observabile. În analiza componentelor principale (PCA), comunalitățile inițiale (înainte de extragere) sunt egale cu 1 (ceea ce ne spune că toată varianța variabilelor este explicată). După extragerea factorilor, comunalitățile în urma extragerii ne arată cât din varianța unei variabile este explicată de factorii extrași. Cu cât mai mare este comunalitatea unei variabile, cu atât mai mult din varianța sa este explicată de factorii reținuți. Comunalitatea unei variabile reprezintă pătratul coeficientului de corelație multiplă dintre variabilă și factorii extrași. Dacă, de exemplu, am salva factorii extrași ca variabile și am aplica metoda regresiei multiple având variabila observabilă ca VD și factorii ca VI, atunci valoarea comunalității este coeficientul R^2 din regresie, iar saturațiile factoriale pentru variabila în cauză sunt coeficienții beta.

Cu cât sunt mai ridicate comunalitățile variabilelor, cu atât mai stabil este modelul factorial analizat. MacCallum (1999) arată că atunci când comunalitățile sunt de nivel mediu sau ridicate, modelul factorial este stabil chiar pe eșantioane reduse dacă factorii sunt bine determinați.

Pe de altă parte, comunalitatea unei variabile este egală cu suma pătratelor saturațiilor acelei variabile în factori. Existența unor comunalități ridicate în cazul unor variabile nu garantează calitatea acestor variabile în modelul factorial. O variabilă poate avea saturații de valori ridicate și apropiate în mai mulți factori, iar de aici rezultă existența unei comunalități ridicate în cazul acelei variabile. În situația unor saturații apropiate ale unei variabile în cel puțin doi factori va trebui să eliminăm acea variabilă, chiar dacă aceasta are o comunalitate ridicată. Pe de altă parte, în selectarea unui model factorial valid vom urmări eliminarea acelor variabile care au comunalități scăzute și saturații scăzute.

22.6. Saturațiile factoriale și importanța acestora

Saturațiile factoriale reprezintă coeficienții de corelație Pearson dintre variabile și factori. Dacă am salva variabilele ca factori, atunci saturația factorială a variabilei C1 în factorul F1 de 0,734 va reprezenta coeficientul de corelație dintre variabila C1 și factorul F1. Aceste saturații vor fi interpretate precum orice coeficient de corelație. Saturația factorială ridicată la pătrat reprezintă proporția din varianță itemului explicată de factorul respectiv. Așadar, 53,87% din varianța itemului C1 este explicată de factorul F1. Adunând *toate* saturațiile factoriale ale unui factor ridicate la pătrat vom obține valoarea eigenvalue corespunzătoare aceluia factor. Valoarea eigenvalue (suma pătratelor saturațiilor factoriale) a unui factor ne arată cât de mult contribuie factorul respectiv la explicarea varianței comune subiacente variabilelor analizate. Procentul total de varianță explicată de un factor poate fi calculată prin împărțirea valorii eigenvalue la numărul de variabile și înmulțirea cu 100. Adunând valorile eigenvalues corespunzătoare fiecărui factor, împărțind suma la numărul total de variabile și înmulțind cu 100 vom obține procentul total de varianță explicată de factorii extrași din totalul varianței variabilelor analizate.

Cât de mare trebuie să fie totuși o saturație factorială pentru a fi considerată importantă în interpretarea factorului? În general, se consideră că o saturație de minim 0,30 este suficient de importantă pentru a contribui la definirea factorului în cauză. Această regulă pleacă de la faptul că o saturație de 0,30 ne spune că aproximativ 10% din varianța variabilei respective este explicată de acel factor.

Stevens (2002, p. 394) pune în legătură importanța saturațiilor factoriale cu mărimea eșantionului, prezentând valorile minime ale saturațiilor care sunt semnificative statistic la pragul $p < 0,01$ (tabelul 22.2).

Tabelul 22.2. Valorile minime ale saturațiilor factoriale pentru a fi semnificative statistic la pragul de semnificație $p < 0,01$ (two-tailed), în funcție de mărimea eșantionului (n) (Stevens, 2002)

n	Saturația minimă	n	Saturația minimă	n	Saturația minimă
50	0,722	180	0,384	400	0,258
80	0,572	200	0,364	600	0,210
100	0,512	250	0,326	800	0,182
140	0,434	300	0,298	1000	0,162

Problema cu aceste saturații este că, la fel ca orice indicator statistic, chiar având valori mici, ele devin semnificative statistic pe eșantioane foarte mari de subiecți. Va trebui să ne raportăm în evaluarea lor și la semnificația practică. De exemplu, o saturație de 0,20 poate fi semnificativă statistic, însă ea ne spune că factorul respectiv explică doar 4% din varianța variabilei în cauză (ceea ce este prea puțin). Lucrurile stau și invers, respectiv variabila explică doar 4% din varianța factorului în cauză, așadar are o pondere prea mică și ar trebui eliminată din analiză. Stevens (2002) recomandă reținerea variabilelor care explică cel puțin 15% din varianța factorului, ceea ce înseamnă că valoarea minimă a unei saturații ar trebui să fie de 0,40 pentru ca variabila respectivă să fie folosită în definirea factorului.

Atunci când în interiorul unui factor avem saturații negative (de exemplu, în factorul F1 itemii C7 și C11), vom ști că itemii respectivi sunt itemi inversați (situația este similară și în cazul variabilelor măsurate prin scorurile la diferite chestionare).

Cum vom defini (interpreta) un factor? Vom lua în calcul variabilele cu saturațiile cele mai ridicate în acel factor și în funcție de ceea ce măsoară aceste variabile vom interpreta (și numi) factorul în cauză. Pe de altă parte, variabilele cu saturații mai reduse în acel factor ne vor ajuta în nuanțarea factorului respectiv.

Ce facem atunci când o variabilă are saturații apropiate în cel puțin doi factori? Acest fapt ne spune că variabila X explică un procent de varianță aproximativ egal atât din factorul A, cât și din factorul B (așadar nu definește clar nici unul dintre cei doi factori) și, prin urmare, ar trebui eliminată din analiză și refăcută analiza factorială.

22.7. Prezentarea rezultatelor

Pentru verificarea validității factoriale a scalei abilităților de comunicare (conținând 14 itemi) am aplicat analiza factorială folosind analiza în componente principale și metoda de rotație Varimax. Am reținut trei factori, pe baza faptului că scala a fost construită pentru a măsura trei dimensiuni: comunicare verbală, mimico-gestuală și emoțională. După rotație, primul factor acoperă 26,23% din varianță, al doilea factor 22,53% din varianță iar al treilea factor 15,37% din varianță. Tabelul 22.3 prezintă itemii și saturațiile factoriale pentru factorii rotați, saturațiile mai mici de 0,30 fiind omise pentru o mai bună claritate.

Tabel 22.3. Saturațiile factoriale pentru factorii rotați

Itemi	Saturația factorială			Comunalități
	Fact. 1	Fact. 2	Fact. 3	
Intru în discuțiile cu ceilalți relativ ușor.	0,787			0,726
Deseori inițiez discuții cu colegii.	0,737			0,593
Sunt o persoană vorbărească.	0,734			0,620
Nu vorbesc prea mult cu colegii.	- 0,713			0,514
Îmi exprim cu ușurință opiniile.	0,703			0,553
Îmi este destul de ușor să-mi expun punctele de vedere într-o conversație.	0,633			0,527
Îmi este greu să-mi exprim gândurile în cuvinte.	- 0,599			0,369
Când discut cu cineva îmi însoțesc cuvintele de gesturi.		0,908		0,833
Obişnuiesc să gesticulez atunci când vorbesc cu alții.		0,870		0,829
În discuțiile cu ceilalți am o mimică și o gestică exuberante.		0,787		0,698
Când comunic îmi accentuez ideile prin voce, mimică sau gestică.		0,741		0,699
Îmi manifest cu ușurință emoțiile în discuțiile pe care le am.			0,807	0,660
Îmi exprim fizic emoțiile.			0,777	0,744
Vocea îmi exprimă sentimentele de bucurie sau tristețe pe care le încerc.			0,7776	0,612
Eigenvalue	30,67	30,15	20,15	
% varianță	260,23	220,53	150,37	

Notă: saturațiile < 0,40 au fost omise.

Primul factor, numit comunicare verbală, este saturat mai puternic de primii șapte itemi, care au saturațiile în a doua coloană. Doi dintre acești itemi măsoară abilitățile scăzute de comunicare verbală și au saturații negative. Al doilea factor, numit comunicare

gestuială, este compus din patru itemi cu saturațiile în coloana a treia. Al treilea factor, numit comunicare emoțională, este compus din trei itemi cu saturațiile în coloana a patra.

Exerciții SPSS

Analiza factorială

1. Deschideți fișierul *Metode_active*. Explorați validitatea factorială a unei scale destinate să măsoare aplicarea metodelor active de predare în activitatea instructiv-educativă. Atenție: în verificarea validității de construct, numărul minim de itemi pe care trebuie să-l conțină un factor este trei.
2. Deschideți fișierul *Intimitate_sociala*. Explorați validitatea factorială a unei scale unidimensionale destinate să măsoare intimitatea socială.

Rezolvarea exercițiilor

Analiza corelațională

1. Deoarece variabilele sunt cantitative și normal distribuite vom calcula coeficientul de corelație Pearson. Corelația între performanță și motivație intrinsecă este $r(60) = 0,414$ ($p < 0,001$), între performanță și motivație extrinsecă este $r(60) = -0,133$ ($p > 0,05$), iar între performanță și autoeficiență este $r(60) = 0,275$ ($p < 0,05$). Raportându-ne la criteriile lui Cohen (1988), prima corelație este de nivel mediu iar a doua și a treia sunt de nivel scăzut.
2. Corelația parțială dintre performanță și motivație intrinsecă, controlând efectul variabilei *autoeficiență*, este $r(59) = 0,337$ ($p < 0,01$). Raportându-ne la criteriile lui Cohen (1988), relația dintre performanță și motivație controlând efectul variabilei *autoeficiență* este de nivel mediu.

Teste t parametrice

1. Pentru a verifica dacă expunerea la jocuri agresive pe calculator a avut efect asupra creșterii agresivității copiilor am aplicat testul t pentru eșantioane perechi. Rezultatele arată că expunerea la jocuri agresive a condus la o creștere semnificativă a agresivității copiilor (înainte de expunere $M = 35,95$, $SD = 7,62$, după expunere $M = 44,18$, $SD = 7,69$), $t(21) = 9,27$ ($p < 9,001$). Mărimea efectului expunerii asupra creșterii agresivității copiilor este $r = 0,90$ (conform formulei 4.4), ceea ce, conform lui Cohen (1988), reprezintă un efect puternic.
2. Elevii din eșantionul testat obțin în medie scoruri mai mari la QI comparativ cu media pe populație ($M = 113,80$, $SD = 15,88$), rezultatele la testul t pentru un eșantion fiind semnificative statistic, $t(29) = 4,76$ ($p < 0,001$). Mărimea efectului calculată aplicând formula (4.4) este $r = 0,66$, ceea ce conform lui Cohen (1988) reprezintă un efect puternic.
3. Pentru a verifica dacă există diferențe semnificative în funcție de stilul parental (democratic *versus* autoritar) în ceea ce privește motivația extrinsecă și autoeficiența copiilor am aplicat testul t pentru eșantioane independente. Rezultatele arată că există diferențe semnificative, copiii beneficiind de un stil parental democratic având o motivație extrinsecă mai dezvoltată ($M = 30,60$, $SD = 5,04$) comparativ cu cei beneficiind de un stil parental autoritar ($M = 27,29$, $SD = 6,40$), $t(74) = 2,51$ ($p < 0,05$). Mărimea efectului calculată prin formula (4.10) este $d = 0,59$, ceea ce conform lui Cohen (1988) reprezintă un efect mediu. De asemenea, copiii beneficiind de un stil parental democratic manifestă o autoeficiență mai dezvoltată ($M = 54,02$, $SD = 8,96$) comparativ cu cei beneficiind de un stil parental autoritar ($M = 44,38$,

$SD = 9,56$), $t(74) = 4,53$ ($p < 0,001$). Mărima efectului calculată prin formula (4.10) este $d = 1,06$, ceea ce conform lui Cohen (1988) reprezintă un efect puternic.

4. Pentru a verifica preferința elevilor pentru una dintre emisiunile TV (divertisment *versus* culturale) am aplicat testul t pentru eșantioane perechi. Rezultatele arată că elevii preferă într-o măsură semnificativ mai mare emisiunile de divertisment ($M = 39,81$, $SD = 8,89$) comparativ cu emisiunile culturale ($M = 35,36$, $SD = 13,99$), $t(41) = 2,41$ ($p < 0,05$). Mărima efectului calculată prin formula (4.4) este $r = 0,35$, ceea ce conform lui Cohen (1988) reprezintă un efect de nivel mediu.

Teste neparametrice

1. Deoarece VD este dihotomică, iar eșantioanele sunt perechi vom aplica testul McNemar. Rezultatele arată că dezbateră TV a avut un efect semnificativ asupra schimbării opțiunilor alegătorilor, $p = 0,035$. Valoarea testului McNemar este $MC(y) = y_{12} - y_{21} = 12 - 3 = +9$, deci pozitivă, prin urmare efectul dezbaterii a fost în favoarea candidatului B. Putem spune că în urma dezbaterii mai multe voturi ale candidatului A au trecut la candidatul B decât invers, de la candidatul B la candidatul A.
2. Deoarece variabilele *veselie* și *imaginație* sunt variabile ordinale, pentru a verifica diferențele existente în funcție de variabilele *gen* și *mediu* vom aplica testul neparametric pentru două eșantioane independente Mann-Whitney U. Rezultatele arată că:
 - există diferențe semnificative în funcție de mediul de proveniență în ceea ce privește importanța acordată valorii *veselie*, $z = -2,025$ ($p < 0,05$), subiecții din mediul urban acordând o mai mare importanță acestei valori ($Mdn = 10$) comparativ cu cei din mediul rural ($Mdn = 5$); mărimea efectului (calculată prin formula 4.18) este $r = 0,24$, ceea ce conform lui Cohen (1988) reprezintă un efect scăzut;
 - nu există diferențe semnificative în funcție de mediul de proveniență în ceea ce privește importanța acordată valorii *imaginație*, $z = -0,608$ ($p > 0,05$);
 - există diferențe semnificative în funcție de gen în ceea ce privește importanța acordată valorii *imaginație*, $z = -2,205$ ($p < 0,05$), subiecții de gen masculin acordând o mai mare importanță acestei valori ($Mdn = 15$) comparativ cu cei de gen feminin ($Mdn = 9,5$); mărimea efectului (calculată prin formula 4.18) este $r = 0,28$, ceea ce conform lui Cohen (1988) reprezintă un efect scăzut;
 - nu există diferențe semnificative în funcție de gen în ceea ce privește importanța acordată valorii *veselie*, $z = -0,648$ ($p > 0,05$).
3. Deoarece toate cele trei valori au fost evaluate de către fiecare subiect prin intermediul aceleiași scale de măsură (ierarhizare de la 1 la 20), pentru a verifica diferențele privind importanța acordată celor două cupluri de valori vom aplica testul neparametric Wilcoxon. Rezultatele arată că există diferențe semnificative între evaluările subiecților asupra importanței valorilor *veselie* și *imaginație*, $z = -2,419$ ($p < 0,05$), subiecții considerând valoarea *imaginație* ca fiind mai importantă ($Mdn = 12$) comparativ cu valoarea *veselie* ($Mdn = 8$), mărimea efectului fiind $r = 0,29$. De asemenea, nu există diferențe semnificative între evaluările subiecților asupra importanței acordate valorilor autocontrol și *imaginație*, $z = 0,939$ ($p > 0,05$).

4. Rezultatele la testul Pearson χ^2 arată că numărul de absențe ale elevilor diferă în funcție de tipul de familie, în sensul că elevii cu peste 20 de absențe care provin din familii monoparentale este semnificativ mai mare comparativ cu elevii având peste 20 de absențe provenind din familii nucleare [$\chi^2(1) = 5,838$, $p = 0,030$] (deoarece una dintre celule are mai puțin de 5 frecvențe, am ajustat pragul de semnificație a testului chi-pătrat conform testului Fischer). Indicatorul mărimii efectului Phi = 0,527, ceea ce conform criteriilor lui Cohen înseamnă că relația dintre cele două variabile este puternică.

ANOVA

1. Pentru că studiem care dintre cele două metode a fost mai eficientă ținând sub control nivelul empatic inițial al subiecților vom aplica tehnica ANCOVA simplă, având ca VI metode, VD *empatie posttest* și covariabilă *empatie pretest*. Dacă grupele ar fi fost omogene anterior intervenției am fi aplicat tehnica ANOVA mixtă (având ca VI metode și momentul testării). Să analizăm rezultatele la ANCOVA. Constatăm că după controlarea nivelului empatic inițial, subiecții cărora li s-a aplicat metoda2 au o empatie mai dezvoltată comparativ cu subiecții cărora li s-a aplicat metoda1, $F(1, 51) = 8,984$, $p < 0,001$, mărimea efectului fiind $r = 0,39$. Verificând condiția omogenității pantelor de regresie obținem un $F_{\text{interacțiune}}(1, 50) = 0,991$ ($p > 0,05$); prin urmare, această condiție este îndeplinită.
2. Designul analizat conține două VI: *sursă* (două trepte: *joc de rol* și *sursă-expert*) și *momentul temporal* (trei trepte: *pretest*, *posttest 1* și *posttest 2*). Cum dintre cele două VI una este cu măsurători repetate (*momentul temporal*) vom aplica metoda ANOVA mixtă. Condiția de simetrie complexă este îndeplinită, Box M = 4,473 ($p > 0,05$). Constatăm că există un efect principal semnificativ al variabilei *moment temporal*, $F(2, 116) = 21,898$ ($p < 0,001$), ceea ce înseamnă că indiferent de sursa influenței, există diferențe semnificative între cele trei momente ale testării: *pretest*, *posttest 1* și *posttest 2* (nu ne interesează analiza amănunțită a acestui efect). În schimb, nu există un efect principal semnificativ al variabilei *sursă*, $F(1, 58) = 1,390$ ($p > 0,05$). Există de asemenea un efect de interacțiune al variabilelor *sursă* și *momentul testării*, $F(2, 116) = 3,436$ ($p < 0,05$). Efectul de interacțiune va fi studiat prin intermediul efectelor simple (tehnica sintaxelor). Pentru efectele simple ale VI *moment* în fiecare dintre condițiile VI *sursă* vom compara *prepost1* și *prepost2*. Atenție: dacă folosim sintaxe, contrastele pentru VI *moment* vor trebui să fie ortogonale (varianta mai simplă); prin urmare vom folosi două sintaxe, una pentru primul contrast (1 -1 0) și o a doua pentru al doilea contrast (1 0 -1)! Pentru primul efect simplu al VI *moment*, în condiția *joc de rol* $F(1, 58) = 2,45$ ($p > 0,05$), mărimea efectului $r = 0,14$, iar în condiția *sursă-expert* $F(1, 58) = 3,74$ ($p > 0,05$), mărimea efectului $r = 0,17$, prin urmare nici un mesaj nu a avut un efect semnificativ asupra schimbării atitudinii subiecților imediat după expunere. Pentru al doilea efect simplu al VI *moment*, în condiția *joc de rol* $F(1, 58) = 50,98$ ($p < 0,001$), mărimea efectului $r = 0,64$ iar în condiția *sursă-expert* $F(1, 58) = 13,46$ ($p < 0,001$), mărimea efectului $r = 0,33$, ceea ce înseamnă că la două luni după expunere ambele mesaje au avut efecte semnificative asupra schimbării atitudinii subiecților. Observăm că la două luni de la expunere influența prin *joc de rol* produce un efect aproape dublu comparativ cu influența prin *sursă-expert*.

3. Deoarece designul conține o singură VI cu trei nivele și două VD numerice vom aplica tehnica ANOVA simplă (one-way) de două ori.

- a) *Influența tipului de motivare asupra atractivității sarcinii.* Verificăm mai întâi dacă sunt îndeplinite condițiile necesare aplicării ANOVA simplă. Analizând normalitatea distribuției VD pentru fiecare treaptă a VI observăm că rezultatele la testul Shapiro-Wilk sunt ne semnificative statistic: pentru grupul *laudă*, $p = 0,137$, pentru grupul *muștrare*, $p = 0,199$, iar pentru grupul de control $p = 0,247$, ceea ce înseamnă că variabila *atractivitate* este normal distribuită pentru fiecare nivel al variabilei *grup*. Rezultatul la testul de omogenitate a varianțelor este Levene $F(2, 57) = 0,225$ ($p > 0,05$), deci și condiția de omogenitate a varianțelor este îndeplinită. Urmărind rezultatele la testul F omnibus ANOVA observăm că $F(2, 57) = 8,262$ ($p < 0,001$), prin urmare există diferențe semnificative între cele trei grupe în ceea ce privește atractivitatea sarcinii. Mai departe vom aplica testul post hoc Tukey. Analizând rezultatele obținute constatăm că grupul 1 (*laudă*) apreciază sarcina ca fiind mai atractivă comparativ cu grupul 2 (*muștrare*), Tukey $t = 3,65$ ($p < 0,01$), mărimea efectului $r_{\text{laudă, muștrare}} = 0,43$, ceea ce conform lui Cohen (1988) reprezintă un efect mediu spre puternic. De asemenea, grupul 3 (de control) apreciază sarcina ca fiind mai atractivă comparativ cu grupul 2 (*muștrare*), Tukey $t = 3,37$ ($p < 0,01$), mărimea efectului $r_{\text{muștrare, control}} = 0,39$, ceea ce conform lui Cohen (1988) reprezintă un efect mediu. În schimb, nu există diferențe semnificative între grupul 1 (*laudă*) și grupul 3 (control) în ceea ce privește atractivitatea sarcinii, Tukey $t = 0,28$ ($p > 0,05$), mărimea efectului fiind $r_{\text{laudă, control}} = 0,03$.
- b) *Influența tipului de motivare asupra intențiilor viitoare de participare în sarcini similare.* Verificăm mai întâi dacă sunt îndeplinite condițiile necesare aplicării ANOVA simplă. Analizând normalitatea distribuției VD pentru fiecare treaptă a VI observăm că rezultatele la testul Shapiro-Wilk sunt ne semnificative statistic: pentru grupul *laudă*, $p = 0,143$, pentru grupul *muștrare*, $p = 0,066$, iar pentru grupul de control $p = 0,263$, ceea ce înseamnă că variabila *intenții* este normal distribuită pentru fiecare nivel al variabilei *grup*. Rezultatul la testul de omogenitate a varianțelor este Levene $F(2, 57) = 1,051$ ($p > 0,05$), deci și condiția de omogenitate a varianțelor este îndeplinită. Urmărind rezultatele la testul F omnibus ANOVA observăm că $F(2, 57) = 8,896$ ($p < 0,001$), prin urmare există diferențe semnificative între cele trei grupe în ceea ce privește intențiile viitoare de participare în sarcini similare. Mai departe vom aplica testul post hoc Tukey. Analizând rezultatele obținute constatăm că subiecții grupului 1 (*laudă*) manifestă intenții viitoare de participare într-o măsură semnificativ mai mare comparativ cu grupul 2 (*muștrare*), Tukey $t = 4,19$ ($p < 0,001$), mărimea efectului $r_{\text{laudă, muștrare}} = 0,48$, ceea ce conform lui Cohen (1988) reprezintă un efect puternic. De asemenea, subiecții grupului 1 (*laudă*) manifestă intenții viitoare de participare într-o măsură semnificativ mai mare comparativ cu grupul 3 (control), Tukey $t = 2,46$ ($p < 0,05$), mărimea efectului $r_{\text{laudă, control}} = 0,28$, ceea ce conform lui Cohen (1988) reprezintă un efect mediu. În schimb, nu există diferențe semnificative între grupul 2 (*muștrare*) și grupul 3 (control) în ceea ce privește intențiile viitoare de participare în sarcini similare, Tukey $t = 1,73$ ($p > 0,05$), mărimea efectului fiind $r_{\text{muștrare, control}} = 0,03$.

Regresie liniară

- Conform rezultatelor la analiza de regresie liniară simplă în care WISC este VD, iar S-B este VI, coeficientul de corelație $R = 0,84$ iar $R^2_{\text{ajustat}} = 0,69$, ceea ce înseamnă că în proporție de aproape 70% scorurile la testul WISC pot fi prezise pe baza scorurilor la testul S-B. Cum intercentul este $a = 7,72$, iar panta de regresie este $b = 0,875$, ecuația de regresie va fi $Y = 7,72 + 0,875 \cdot X \Leftrightarrow WISC = 7,72 + 0,875 \cdot SB$. Pe baza acestei ecuații de regresie vom putea prezice QI-ul unui subiect la testul WISC pe baza QI-ului obținut la testul S-B. Astfel, $QI_{WISC} = 7,72 + 0,875 \cdot 112 = 105,72 \approx 106$. Așadar, cu o precizie de 70%, putem prezice că un individ care a obținut un QI de 112 la testul S-B va obține un QI de 106 la testul WISC.
- Vom aplica metoda regresiei ierarhice. În primul model vom introduce VI *suport* și *autonomie*, iar în al doilea model vom adăuga alături de variabilele primului model variabila *motivație*. Conform rezultatelor obținute, observăm că primul model (factorii familiali) explică 45,2% din varianța variabilei *performanță*, $R^2_{\text{ajustat}} = 0,452$. Modelul doi, în care alături de factorii familiali am adăugat variabila *motivație*, explică 67,3% din varianța variabilei *performanță*, $R^2_{\text{ajustat}} = 0,673$, cu 22% mai mult decât primul model ($\Delta R^2 = 0,220$) iar această creștere este semnificativă, $F_{\text{schimbare}}(1, 128) = 87,97$ ($p < 0,001$). Prin urmare, controlând factorii familiali *suport* și *autonomie* parentală, motivația elevilor explică 22% din performanța acestora. Inspectând coeficienții B și Beta constatăm că aceștia sunt semnificativi pentru fiecare VI în fiecare dintre cele două modele. Conform coeficienților standardizați Beta din al doilea model, ponderea cea mai mare în explicarea performanței o are motivația ($\beta = 0,512$), urmând apoi suportul parental ($\beta = 0,371$) și autonomia parentală ($\beta = 0,296$). Urmărind statisticile de coliniaritate observăm că valorile Tolerance sunt ridicate (peste limita minimă admisă, $1 - R^2_{\text{ajustat}} = 1 - 0,673 = 0,327$) în cazul modelului doi, prin urmare condiția de evitare a multicoliniarității este îndeplinită. Pentru identificarea posibilelor cazuri extreme urmărim dacă valorile minime și maxime ale Std Residual și Stud. Residual se află în afara intervalului $[-2; +2]$; cum în cazul nostru valorile minime și maxime depășesc acest interval, verificăm în baza de date câte astfel de cazuri există. Constatăm că există patru astfel de cazuri (subiecții 86, 17, 26 și 98), însă aceștia reprezintă mai puțin de 5% din totalul subiecților; prin urmare putem considera că este îndeplinită și condiția de evitare a cazurilor extreme, iar ecuația de regresie este relativ stabilă. Verificând dacă există cazuri influente, constatăm că valoarea maximă a distanței lui Cook este 0,05 ($< 1,0$), prin urmare și condiția evitării cazurilor influente este îndeplinită. În sfârșit, inspectând graficele constatăm că reziduurile sunt normal distribuite și necorelate cu predictorii, așadar și această condiție este îndeplinită. Pentru indicatorii mărimii efectului fiecărei VI asupra VD inspectăm coeficienții de corelație semipartială (Part). În cazul modelului 2, mărimea efectului variabilei *motivație* asupra variabilei *performanță* este $r_{SP \text{ motivație}} = 0,47$ (un efect puternic conform lui Cohen, 1988), mărimea efectului variabilei *suport* este $r_{SP \text{ suport}} = 0,33$ (efect mediu), iar mărimea efectului variabilei *autonomie* este $r_{SP \text{ autonomie}} = 0,28$ (efect mediu). Așadar, controlând factorii familiali *suport* și *autonomie*, *motivația* elevilor are un efect puternic asupra *performanței școlare* a acestora.

Analiza fidelității scalelor

1. Coeficientul de fidelitate alfa Cronbach al scalei *stimă de sine* este $\alpha = 0,78$.
2. Coeficientul de fidelitate alfa Cronbach al subscalei *comunicare mimico-gestuală* este $\alpha = 0,89$.
3. Coeficientul de fidelitate alfa al scalei *intimitate socială* conținând 17 itemi este $\alpha = 0,89$. Totuși, constatăm că itemul 14 are un coeficient de corelație corectată extrem de scăzut (0,026), fapt ce ne sugerează eliminarea itemului din scală. După eliminarea itemului 14, coeficientul alfa crește, $\alpha = 0,92$.

Analiza factorială

1. Raportându-ne la criteriul lui Kaiser (eigenvalue peste 1,0) ar trebui să extragem doi factori. Aplicând metoda de rotație oblică observăm o corelație ridicată între cei doi factori extrași (0,39), ceea ce impune păstrarea acestui tip de rotație, și nu alegerea rotației ortogonale. În această situație factorul 2 conține 2 itemi (m1 și m2), iar cum numărul minim de itemi per factor este 3 în cazul explorării validității factoriale, vom aplica din nou analiza factorială, de această dată extrăgând un singur factor. Procentul de varianță explicat de acest factor unic este 54,47%, ceea ce exprimă o bună validitate factorială a acestei scale unidimensionale.
2. Deoarece scala a fost construită ca fiind unidimensională vom extrage un singur factor. Analizând saturațiile itemilor în factor constatăm că itemul 14 are o saturație sub 0,30 și de asemenea o comunalitate foarte scăzută, fapt ce ne sugerează îndepărtarea acestui item din scală și reaplicarea analizei factoriale. După eliminarea itemului 14, varianta explicată de factorul unic crește de la 48,32% la 51,34%, ceea ce ne îndreptățește o dată în plus să eliminăm itemul 14 din scală. Așadar, scala de intimitate socială (conținând 16 itemi, după eliminarea itemului 14) are o bună validitate factorială.

Bibliografie

- APA, 2003, *Publication manual of the American Psychological Association* (ed. a VI-a), American Psychological Association, Washington, DC.
- Argyrous, G., 2005, *Statistics for Research With a Guide to SPSS*, Sage Publications.
- Coakes, S.J., 2005, *SPSS Analysis Without Anguish: Version 12.0 for Windows*, John Wiley & Sons.
- Cohen, J., 1988, *Statistical Power Analysis for the Behavioral Sciences*, Lawrence Erlbaum Associates, Inc.
- Culic, I., 2004, *Metode avansate în cercetarea socială. Analiza multivariată de interdependență*, Polirom, Iași.
- Dancey, C.P.; Reidy, J., 2002, *Statistics Without Math for Psychology*, Prentice Hall.
- Dziuban, C.D.; Shirkey, E.C., 1974, „When is a Correlation Matrix Appropriate for Factor Analysis? Some Decision Rules”, *Psychological Bulletin*, 81, pp. 358-361.
- Fabrigar, L.R.; Wegener, D.T.; MacCallum, R.C.; Strahan, E.J., 1999, „Evaluating the Use of Exploratory Factor Analysis in Psychological Research”, *Psychological Methods*, 4, pp. 272-299.
- Field, A., 2002, *Discovering Statistics Using SPSS for Windows*, Sage Publications.
- Flyod, F.J.; Widaman, K.F., 1995, „Factor analysis in the development and refinement of clinical assessment instruments”, *Psychological Assessment*, 7, pp. 286-299.
- Furr, R.M., 2005, „Effect Sizes and Their Links to Inferential Statistics”, accesat la <http://www.wfu.edu/~furr/rm/EffectSizeFormulas.pdf>.
- Gibbons, J.D., 1993, *Nonparametric Statistics: an introduction*, Sage Publications.
- Gorsuch, R.L., 1997, „Exploratory Factor Analysis: Its Role in Item Analysis”, *Journal of Personality Assessment*, 68, pp. 532-560.
- Guadagnoli, E.; Velnicer, W.F., 1988, „Relation of sample size to the stability of component patterns”, *Psychological Bulletin*, 103, pp. 265-275.
- Havârneanu, C., 2000, *Cunoașterea psihologică a persoanei*, Polirom, Iași.
- Havârneanu, C., 2000, *Metodologia cercetării în științele sociale*, Erola, Iași.
- Henson, R.K.; Roberts, J.K., 2006, „Use of Exploratory factor Analysis in Published Research”, *Educational and Psychological Measurement*, 66, pp. 393-416.
- Ho, R., 2006, *Handbook of Univariate and Multivariate Data Analysis and Interpretation with SPSS*, Taylor & Francis Group.
- Howitt, D.; Cramer, D., 2006, *Introducere în SPSS pentru psihologie*, Polirom, Iași.
- Iacobucci, D., 2001, *Methodological and statistical concerns of the experimental behavioral researcher*, Lawrence Erlbaum Associates, Inc.
- Jaba, E.; Grama, A., 2004, *Analiza statistică cu SPSS sub Windows*, Polirom, Iași.
- Kaiser, H.F.; Rice, J., 1974, „Little Jiffy, Mark IV”, *Educational and Psychological Measurement*, 34, pp. 111-117.
- Leech, N.L.; Barrett, K.C.; Morgan, G.A., 2005, *SPSS for Intermediate Statistics: Use and Interpretation*, Lawrence Erlbaum Associates, Inc.
- Lomax, R.G., 2001, *Statistical concepts. A second course for education and the behavioral sciences*, Lawrence Erlbaum Associates, Inc.
- Lungu, O., 2001, *Ghid introductiv pentru SPSS 10.0*, Erola, Iași.

- MacCallum, R.C.; Widaman, K.F.; Zhang, S.; Hong, S., 1999, „Sample Size in Factor Analysis”, *Psychological Methods*, 4, pp. 84-99.
- Metha, C.R.; Patel, N.R., 1996, *SPSS Exact Tests 7.0 for Windows*, SPSS Inc.
- Morgan, G.A.; Leech, N.L.; Gloeckner, G.W.; Barrett, K.C., 2004, *SPSS for Introductory Statistics: Use and Interpretation*, Lawrence Erlbaum Associates, Inc.
- Norusis, M.J., 1993a, *SPSS for Windows: Profesional Statistics, Release 6.0*, SPSS Inc.
- Norusis, M.J., 1993b, *SPSS for Windows: Advanced Statistics, Release 6.0*, SPSS Inc.
- Page, M.C.; Braver, S.L.; MacKinnon, D.P., 2003, *Levine's Guide to SPSS for Analysis of Variance*, Lawrence Erlbaum Associates, Inc.
- Pedhazur, E.J.; Pedhazur-Schmelkin, L., 1991, *Measurement, Design, and Analysis: An Integrated Approach*, Lawrence Erlbaum Associates, Inc.
- Popa, Marian, 2008, *Statistică pentru psihologie. Teorie și aplicații SPSS*, Polirom, Iași.
- Radu, I. et al., 1993, *Metodologie psihologică și analiza datelor*, Sincron, Cluj-Napoca.
- Rateau, P., 2004, *Metodele și statisticile experimentale în științele umane*, Polirom, Iași.
- Rosenthal, R.; Rosnow, R.L.; Rubin, D.B., 2000, *Contrasts and effect sizes in behavioral research. A corelational approach*, Cambridge University Press, Cambridge, UK.
- Rotariu, T. et al., 1999, *Metode statistice aplicate în științele sociale*, Polirom, Iași.
- Rotariu, T.; Bădescu, G.; Comșa, M.; Culic, I.; Elemer, M.; Lungu, O.; Sava, F.; Marian, C., *Cursurile școlii naționale de statistică socială*, organizate de Facultatea de Științe Politice și Administrație Publică, Universitatea „Babeș-Bolyai” și Fundația SOROS, mai 2001, Cluj-Napoca.
- Russell, D.W., 2002, „In Search of Underlying Dimensions: The Use (and Abuse) of Factor Analysis”, *Personality and Social Psychology Bulletin*, *Personality and Social Psychology Bulletin*, 28, pp. 1629-1646.
- Sava, F.A., 2004, *Analiza datelor în cercetarea psihologică. Metode statistice complementare*, ASCR, Cluj-Napoca.
- Schwab, D.P., 2005, *Research Methods for Organizational Studies*, Lawrence Erlbaum Associates, Inc.
- SPSS, 1999, *SPSS Base 9.0 Applications Guide*, SPSS Inc., Chicago.
- SPSS, 2003, *SPSS Base 12.0 User's Guide*, SPSS Inc., Chicago.
- Stan, A.; Clocotici, V., 2000, *Statistica aplicată în psihologie*, Polirom, Iași.
- Stevens, J., 1992, *Applied multivariate statistics for the social sciences*, Lawrence Elbaum.
- Tinsley, H.E.A.; Tinsley, D.J., 1987, „Uses of Factor Analysis in Counseling Psychology Research”, *Journal of Counseling Psychology*, 34, pp. 414-424.
- Velicer, W.F.; Fava, J.L., 1998, „Effect of Variable and Subject Sampling on Factor Pattern Recovery”, *Psychological Methods*, 3, pp. 231-251.
- Wilkinson, L.M.; The APA Task Force on Statistical Inference, 1999, „Statistical Methods in Psychology Journals: Guidelines and Explanations”, *American Psychologist*, vol. 54, nr. 8, pp. 594-604.
- Zwick, W.R.; Velicer, W.F., 1986, „Compariosn of Five Rules for Determining the Number of Components to Retain”, *Psychological Bulletin*, 99, pp. 432-442.

Index tematic

A

- Abaterea standard 29-30, 45, 182, 203, 206, 218, 241, 245, 260, 318
- Alfa Cronbach, vezi fidelitatea 299-300, 303-304, 340
- Analiza de varianță ANOVA 162-273
 - ANCOVA 262-273
 - ANOVA factorială 184-213
 - ANOVA factorială cu măsurători repetate 224-241
 - ANOVA simplă 162-183
 - ANOVA simplă cu măsurători repetate 214-223
 - ANOVA mixtă 242-261
- Analiza direcțională, vezi ANOVA simplă 168-170
- Analiza factorială exploratorie 305-334
 - Adecvarea variabilelor 308-309
 - Aplicarea în SPSS 317-323
 - Comunalitățile 331
 - Condiții 306-310
 - Interpretarea outputului 323-330
 - Mărimea eșantionului 306-308
 - Metode de extragere a factorilor 311-312
 - Metode de rotație 312-313
 - Numărul factorilor extrași 314-317
 - Optimizarea modelului 310-311
 - Prezentarea rezultatelor 333-334
 - Saturațiile factoriale 331-332
- Analiza răspunsurilor multiple 61-73
 - Răspunsuri multiple 66-69
 - Răspunsuri multiple dihotomice 61-66
 - Răspunsuri multiple în funcție de o variabilă nominală 70-73
- ANCOVA 262-273
 - Aplicație în SPSS 263-264
 - Condiții 263
 - Interpretarea outputului 265-267
 - Mărimea efectului 266, 271
 - Prezentarea rezultatelor 271-273
- ANOVA factorială 184-213
 - Analiza contrastelor de interacțiune 206-209
 - Analiza efectelor principale 188-189
 - Analiza efectelor de interacțiune 189-190
 - Analiza efectelor simple 190-203
 - Aplicație în SPSS 186-187
 - Condiții 184-185
 - Interpretarea outputului 187-188
 - Mărimea efectului 189, 204, 209
- ANOVA factorială cu măsurători repetate 224-241
 - Analiza contrastelor de interacțiune 239-240
 - Analiza efectelor de interacțiune 232-240
 - Analiza efectelor principale 229-232
 - Analiza efectelor simple 233-238
 - Aplicație în SPSS 224-227
 - Condiții 224
 - Interpretarea outputului 227-229
 - Mărimea efectelor 240-241
 - Prezentarea rezultatelor 241
- ANOVA mixtă 242-261
 - Analiza contrastelor de interacțiune 256-259
 - Analiza efectelor de interacțiune 249-259
 - Analiza efectelor principale 247-249
 - Analiza efectelor simple 249-256
 - Aplicație în SPSS 243-244
 - Condiții 242
 - Interpretarea outputului 245-247
 - Mărimea efectelor 259-260
 - Prezentarea rezultatelor 260-261
- ANOVA simplă, One-Way 162-183
 - Analiza direcțională 168-170
 - Aplicație în SPSS 170-172
 - Condiții 162
 - Interpretarea outputului 172-175
 - Mărimea efectului 170
 - Teste de contrast 165-168
 - Teste post hoc 163-165

ANOVA simplă cu măsurători repetate 214-223
 Aplicație în SPSS 215-218
 Condiții 214-215
 Interpretarea outputului 218-222
 Mărima efectului 222-223
 Prezentarea rezultatelor 223
 Teste de contrast 215, 219, 223
 Teste post hoc 215, 217, 219-220, 223

C

Cazuri extreme 85, 275, 277, 280, 284, 295-297, 339
 Cazuri influente 275, 277, 280, 284, 295-297, 339
 Coeficientul ρ Spearman 84, 87-89, 118, 155
 Coeficientul d Sommer 118, 124-126
 Coeficientul de determinare 82, 87, 278, 285, 288, 290-291, 293
 Coeficientul Eta 82, 118
 Coeficientul Gamma 118, 124-127
 Coeficientul Goodman 118, 121-123
 Coeficientul Kruskal t 118, 121-123
 Coeficientul Lambda 118-123
 Coeficientul ϕ 113-114, 117, 337
 Coeficientul r Pearson 84-87, 113, 118, 263, 266-267, 278, 285, 287, 293, 302, 328, 330-331, 335
 Coeficientul tau-b Kendall 84, 90-91, 118
 Coeficientul tau-c Kendall 118
 Coeficientul V al lui Cramer 82, 111, 113
 Coeficienți de contrast 165-167, 177, 179, 197-198, 209, 236, 258
 Coeficienți de corelație 75, 84-87, 89-90, 102-103, 113, 118, 155, 205, 214, 263, 266, 278-279, 282, 285-286, 288, 290, 293, 301-302, 304, 319, 323-324, 327-328, 330-331, 335, 339-340
 Coeficienți de corelație parțială 84, 92, 285, 288
 Coeficienți de corelație semiparțială, vezi regresia 293-294, 339
 Coeficienții epsilon 218-219, 228, 246
 Coliniaritate 288, 292-293, 339
 Comunalități 307-308, 310-311, 314, 319, 325, 327, 329, 331, 333, 340

Contraste

Complexe 166
 Contraste de interacțiune, vezi ANOVA 13, 185, 190, 204-210, 231-232, 239-240, 249, 256, 258
 Nestandardizate 166-167, 177-179, 201, 229
 Nonortogonale 166-167, 177-179, 201, 236, 239, 254, 258
 Ortogonale 166-167, 179, 197, 236, 239-240, 254, 258-259, 337
 Polinomiale 167-170
 Simple 165-167, 201, 226
 Standardizate 167-168, 180-182, 201, 215, 229
 Corecția Bonferroni 164, 178
 Corelația
 Kendall 90-91
 Parțială 91-94
 Pearson 84-87, 92, 274, 330
 Spearman 87-89, 155

D

Determinant 309, 319, 323
 Direct oblimin 313, 321, 329
 Dispersie 30, 164, 203, 241, 260
 Distanța lui Cook 277, 280, 289, 296-297, 339

E

Efecte de interacțiune, vezi ANOVA 189-190, 232-240, 249-259
 Efecte principale, vezi ANOVA 188-189, 229-232, 247-249
 Efecte simple, vezi ANOVA 190-203, 233-238, 249-256
 Eigenvalue (valori de bază) 314-316, 320, 325-326, 329, 331, 333, 340
 Equamax 313, 321
 Erori în testarea ipotezelor 74-75
 Eroarea de tipul I 74-75, 164, 179, 191
 Eroarea de tipul II 74-75, 179, 191
 Exerciții
 Analiza corelațională 94
 Analiza factorială 334
 Analiza fidelității scalelor 304

ANOVA 272-273
 Regresia liniară 298
 Teste neparametrice 161
 Teste t parametrice 103

F

Fidelitatea, coeficientul alfa Cronbach 299-304
 Aplicație în SPSS 299-301
 Condiții 299
 Interpretarea outputului 301-303
 Observații 304
 Fisher 109, 112, 116
 Frecvențe 33, 39, 42, 46, 48-49, 61, 73,
 106-109, 112, 116, 123, 337
 Frecvențe marginale 123
 Frecvențe marginale standardizate 123

G

Grade de libertate 86, 93, 116, 148, 173,
 178, 188, 214, 218-219, 223
 Grafice 39-60
 Grafice sub formă de bare 39, 46, 52,
 174
 Grafice sub formă de cerc 33, 36, 46
 Graficul Scree al lui Cattell 315-316, 320,
 326, 329
 Histogramă 44-46, 48-49, 75-76, 78,
 294
 Q-Q plots 44, 46-48
 Scatterplot 58-59, 263, 266, 284, 295
 Greenhouse-Geisser 214, 218-219, 229, 246,
 257

H

Heteroscedasticitate 284
 Homoscedasticitatea 284, 295
 Huynh-Feldt 214, 218-219, 229, 246, 257

I

Ipoteze 74-83
 Bidirecționale 74, 86, 116, 163
 Unidirecționale 74, 116, 155, 163, 165

K

Kaiser-Meyer-Olkin (KMO) 308-309, 318-319,
 324
 Kurtosis, vezi normalitatea unei distribuții
 30, 80-81

M

Matricea de corelație 92, 245, 298, 301,
 305, 308-309, 318-320, 323-324
 Matricea de covarianță antiimagine 308-309,
 320, 324
 Mărima efectului 82-83, 113-114, 170
 ANOVA factorială 189, 204, 209
 ANOVA factorială cu măsurători repetate
 240
 ANOVA simplă 170
 ANOVA simplă cu măsurători repetate
 222-223
 Corelația Kendall 91
 Corelația parțială 93
 Corelația Pearson 87
 Corelația Spearman 89
 Indicatori ai mărimii efectului 82, 113,
 279, 294, 297, 339
 Regresia liniară multiplă 294
 Coeficienții de corelație semiparțială r_{sp}
 294
 R, R^2 ajustat 294
 Regresia liniară simplă 279
 R, R^2 ajustat 279
 Testul χ^2 de asociere 113-114
 Teste de asociere cu o variabilă nominală
 și una ordinală 121
 Testul Mann-Whitney U 131
 Testul t pentru două eșantioane indepen-
 dente 99
 Testul t pentru două eșantioane perechi
 103
 Testul t pentru un eșantion 97
 Testul Wilcoxon 139
 Măsuri ale asocierii 109-127
 Asimetrice 120
 χ^2 de asociere 109-117
 Coeficientul d Sommer 118, 124-126
 Coeficientul Gamma 118, 124-127

Coeficientul Lambda 118-123
 Simetrice 117, 124
 Mediană 29-32, 128-129, 132-133, 139, 145, 150-155
 Medie 29-32, 45, 51, 82, 91, 95-96, 99, 102, 105, 129, 131, 137, 139, 148, 158, 163, 165-167, 169, 172-176, 188, 302, 322, 335
 Multicolinearitate 263, 284, 287-288, 293, 304, 309, 319, 323, 339
 Normalitatea unei distribuții 75-76, 79, 276, 289, 294, 338
 Coeficientul de asimetrie Skewness 30, 80-81
 Coeficientul de boltire Kurtosis 30, 80-81
 Histogramă 44-46, 78, 276, 289, 294
 Testul Kolmogorov-Smirnov 75, 77-81, 87, 171, 294
 Testul Shapiro-Wilk 79-81, 171, 294, 338

O

Omogenitatea pantelor de regresie 263, 267-271, 337
 Omogenitatea varianțelor 81, 97, 99, 135, 162, 172-173, 178, 214, 245, 263, 265, 338

P

Prezentarea rezultatelor
 Analiza factorială exploratorie 333-334
 ANCOVA 271-273
 ANOVA factorială 203-204
 ANOVA factorială cu măsurători repetate 241
 ANOVA mixtă 260-261
 ANOVA simplă 182-183
 ANOVA simplă cu măsurători repetate 223
 Corelația Pearson 87
 Regresia liniară multiplă 297-298
 Regresia liniară simplă 283
 Testul χ^2 de asociere 117

Testul Jonckheere-Terpstra J 155
 Testul Kruskal-Wallis H 151-152
 Testul Mann-Whitney U 133-134
 Testul t pentru eșantioane independente 100
 Testul Wilcoxon 140
 Procentul de varianță cumulată explicată 82, 311-312, 316, 325, 332, 340
 Promax 313, 321

Q

Quartimax 313, 321

R

Regresia 274-298
 Aplicarea în SPSS 275-277, 285-290
 Coeficienți de corelație parțială 285, 288
 Coeficienți de corelație semiparțială 293-294
 Coeficienții B nestandardizați 279, 288, 292
 Coeficienții Beta standardizați 279
 Coliniaritate 288, 292-293
 Condiții 275, 284
 Interpretarea outputului 278-280, 290-293
 Mărimea efectului 279, 294
 Metode de analiză 274, 283-290
 Prezentarea rezultatelor 283, 297-298
 Reziduuri standardizate 289, 294-295
 Verificarea asumpțiilor 294-297
 Reziduuri 106, 108, 112-113, 122, 276, 284, 289, 294-295, 316-317, 319, 327-328, 339
 Rezolvarea exercițiilor
 Analiza corelațională 335
 Analiza factorială 340
 Analiza fidelității scalelor 340
 ANOVA 337-338
 Regresia liniară 339
 Teste neparametrice 336-337
 Teste t parametrice 335-336
 Rotații oblice 313, 321, 330
 Rotații ortogonale 313, 321, 330

S

- Saturații factoriale 306-308, 310-312, 315, 321, 328-333, 340
- Sfericitatea 214, 218-219, 228, 242, 245, 263, 308-309, 319, 324
- Simetria complexă 242, 245, 337
- Singularitatea 309, 319
- Skewness, vezi normalitatea unei distribuții 30, 80-81

T

- Teste asimetrice 117
- Teste neparametrice 104-108, 128-161
 - Testul binomial 104-105
 - Testul χ^2 de ajustare 106-108
 - Testul Cochran Q 159-161
 - Testul Friedman 157-159
 - Testul Joncheere-Terpstra J 152-156
 - Testul Kolmogorov-Smirnov Z 87, 134
 - Testul Kruskal-Wallis H 145-152
 - Testul Mann-Whitney U 128-134
 - Testul McNemar 142-144
 - Testul Moses extreme reactions 134-135
 - Testul semnelui (Sign Test) 140-142
 - Testul Wald-Wolfowitz runs 134-135

- Testul Wilcoxon 136-140
- Teste simetrice 117
- Teste t parametrice 95-103
 - Testul t pentru un eșantion 95-97
 - Testul t pentru eșantioane independente 97-100
 - Testul t pentru eșantioane perechi 100-103
- Testul Barlett de sfericitate 308-309, 318-319, 324
- Testul Bonferroni 164, 176, 215, 220, 223, 225, 240, 243, 247-248, 250
- Testul Box M 245, 337
- Testul Levene 97, 99, 135, 162, 164, 173, 187-188, 193, 195, 211, 213, 243, 245, 265, 338
- Testul Mauchly W 218
- Testul Tukey 163-164, 175-177, 182-183, 338

V

- Varianța 30, 82, 87, 135, 162-164, 172-173, 175, 178, 182, 184, 187-188, 214, 242, 245, 262-263, 265, 269, 272, 274, 278-279, 283-284, 290-293, 297, 302, 305, 311-312, 316, 320, 325, 329, 331-333, 337-340
- Varimax 313, 321, 328-329, 333

COLLEGIUM. Științele educației

au apărut :

Gabriel Albu – *Introducere într-o pedagogie a libertății. Despre libertatea copilului și autoritatea adultului*

Liviu Antonesei – *Paideia. Fundamentele culturale ale educației*

Liviu Antonesei, Dr. Yehia A.I. Abdel-Aal, Mohamed R. El-Tahlawi,
Dr. Nabila T. Hassan – *Managementul universitar. De la viziunea conducerii la misiunea de succes*

Carmen Crețu – *Psihopedagogia succesului*

Constantin Cucuș – *Istoria pedagogiei. Idei și doctrine fundamentale*

Geneviève Meyer – *De ce și cum evaluăm*

Adrian Miroiu (coord.), Vladimir Pasti, Cornel Codiță, Gabriel Ivan,
Mihaela Miroiu – *Învățământul românesc azi*

J.M. Monteil – *Educație și formare. Perspective psihosociale*

André de Péretti, Jean-André Legrand, Jean Boniface – *Tehnici de comunicare*

Elena Joița – *Management educațional*

Horst Schaub, Karl G. Zenke – *Dicționar de pedagogie*

Jean Voegler (coord.) – *Evaluarea în învățământul preuniversitar*

Lavinia Bârlogeanu – *Psihopedagogia artei. Educația estetică*

Ioan Cerghit, Ioan Neacșu, Ion Negreț-Dobridor, Ion-Ovidiu Pânișoară – *Prelegeri pedagogice*

Liviu Antonesei – *O introducere în pedagogie. Dimensiunile axiologice și transdisciplinare ale educației*

Gabriel Albu – *În căutarea educației autentice*

Emil Păun, Romiță Iucu (coord.) – *Educația preșcolară în România*

Viorel Ionel – *Pedagogia situațiilor educative*

Constantin Cucuș – *Pedagogie* (ediție revăzută și adăugită)

Elena Joița – *Educația cognitivă. Fundamente. Metodologie*

Mariana Momanu – *Introducere în teoria educației*

Ion-Ovidiu Pânișoară – *Comunicarea eficientă. Metode de interacțiune educațională*

Adrian Neculau – *Educația adulților. Experiențe românești*

Ion-Ovidiu Pânișoară – *Comunicarea eficientă* (ediția a II-a revăzută și adăugită)

Ion Negreț-Dobridor, Ion-Ovidiu Pânișoară – *Știința învățării. De la teorie la practică*

Ioan Cerghit – *Metode de învățământ* (ediția a IV-a revăzută și adăugită)

Romiță B. Iucu – *Managementul clasei de elevi. Aplicații pentru gestionarea situațiilor de criză educațională*

Alois Gherguț – *Psihopedagogia persoanelor cu cerințe speciale. Strategii diferențiate și incluzive în educație* (ediția a II-a revăzută și adăugită)

Alois Gherguț – *Management general și strategic în educație. Ghid practic*
Ramona Paloș, Simona Sava, Dorel Ungureanu (coord.) – *Educația adulților.*
Baze teoretice și repere practice

Ion Al. Dumitru – *Consiliere psihopedagogică. Baze teoretice și sugestii practice*

Ion Negreț-Dobridor – *Teoria generală a curriculumului educațional*

Constantin Cucos – *Teoria și metodologia evaluării*

Ion-Ovidiu Pânișoară – *Comunicarea eficientă* (ediția a III-a revăzută și adăugită)

Lucian Ciolan – *Învățarea integrată. Fundamente pentru un curriculum transdisciplinar*

Adrian Vicențiu Labăr – *SPSS pentru științele educației. Metodologia analizei datelor în cercetarea pedagogică*

în pregătire :

Romiță B. Iucu – *Instruirea școlară. Perspective teoretice și aplicative* (ediția a II-a revăzută și adăugită)

Dan Potolea, Ioan Neacșu, Romiță Iucu, Ion-Ovidiu Pânișoară (coord.) – *Pregătirea psihopedagogică. Manual pentru defăiniv și gradul didactic II*

Ioan Cerghit – *Sisteme de instruire alternative și complementare. Structuri, stiluri și strategii* (ediția a II-a revăzută și adăugită)

Anca Nedelcu – *Fundamentele educației interculturale. Diversitate, minorități, echitate*

www.polirom.ro

Coperta: Laurențiu Midvichi

Tehnoredactor: Radu Căpraru

Bun de tipar : august 2008. Apărut : 2008

Editura Polirom, B-dul Carol I nr. 4 • P.O. Box 266
700506, Iași, Tel. & Fax (0232) 21.41.00; (0232) 21.41.11;
(0232) 21.74.40 (difuzare); E-mail: office@polirom.ro
București, B-dul I.C. Brătianu nr. 6, et. 7, ap. 33,
O.P. 37 • P.O. Box 1-728, 030174

Tel. : (021) 313.89.78; E-mail : office.bucuresti@polirom.ro

Tiparul executat la S.C. LUMINA TIPO s.r.l.
str. Luigi Galvani nr. 20 bis, sect. 2, București

Tel./Fax : 211.32.60, 212.29.27, E-mail : office@luminatipo.com

**Științele
educației**

Adrian Vicențiu Labăr

SPSS PENTRU ȘTIINȚELE EDUCAȚIEI

Concepută ca un ghid de utilizare a pachetului de programe statistice SPSS, lucrarea prezintă metodologia analizei datelor specifice științelor educației. Descrierea fiecărei tehnici de calcul conține o prezentare generală, condițiile ce trebuie îndeplinite pentru aplicarea tehnicii respective, exemple și exerciții, precum și interpretarea outputului obținut în SPSS. *SPSS pentru științele educației* se adresează studenților și cercetătorilor din câmpul educațional, dar și celor din domenii conexe precum psihologia, sociologia și marketingul.

Analiza răspunsurilor multiple • Analiza corelațională • Teste parametrice • Teste neparametrice • ANOVA simplă • ANOVA factorială • ANOVA cu măsurători repetate • ANOVA mixtă • ANCOVA • Regresia liniară simplă • Regresia liniară multiplă • Fidelitatea (Reliability Analysis) • Analiza factorială exploratorie

Collegium

EDITURA POLIROM
www.polirom.ro

ISBN 978-973-46-1148-5



9 789734 611485